



(43) Internationales Veröffentlichungsdatum 14. Juni 2001 (14.06.2001)

(10) Internationale Veröffentlichungsnummer WO 01/42493 A2

(51) Internationale Patentklassifikation7:

C12Q 1/68 PCT/DE00/04381

(21) Internationales Aktenzeichen: (22) Internationales Anmeldedatum:

6. Dezember 2000 (06.12.2000)

(25) Einreichungssprache:

Deutsch

(26) Veröffentlichungssprache:

Deutsch

(30) Angaben zur Priorität:

199 59 691.3 6. Dezember 1999 (06.12.1999)

- (71) Anmelder (für alle Bestimmungsstaaten mit Ausnahme von US): EPIGENOMICS AG [DE/DE]; Kastanienallee 24, D-10435 Berlin (DE).
- (72) Erfinder; und
- (75) Erfinder/Anmeider (nur für US): OLEK, Alexander [DE/DE]; Kyffhäuserstrasse 20, D-10781 Berlin (DE). PIEPENBROCK, Christian [DE/DE]; Schwartzkopffstrasse 7 B, D-10115 Berlin (DE).
- (74) Anwalt: SCHUBERT, Klemens; Joachimstrasse 9, D-10119 Berlin (DE).

- (81) Bestimmungsstaaten (national): AE, AG, AL, AM, AT, AU, AZ, BA, BB, BG, BR, BY, BZ, CA, CH, CN, CR, CU, CZ, DE, DK, DM, DZ, EE, ES, FI, GB, GD, GE, GH, GM, HR, HU, ID, IL, IN, IS, JP, KE, KG, KP, KR, KZ, LC, LK, LR, LS, LT, LU, LV, MA, MD, MG, MK, MN, MW, MX, MZ, NO, NZ, PL, PT, RO, RU, SD, SE, SG, SI, SK, SL, TJ, TM, TR, TT, TZ, UA, UG, US, UZ, VN, YU, ZA, ZW.
- (84) Bestimmungsstaaten (regional): ARIPO-Patent (GH, GM, KE, LS, MW, MZ, SD, SL, SZ, TZ, UG, ZW), eurasisches Patent (AM, AZ, BY, KG, KZ, MD, RU, TJ, TM), europäisches Patent (AT, BE, CH, CY, DE, DK, ES, FI, FR, GB, GR, IE, IT, LU, MC, NL, PT, SE, TR), OAPI-Patent (BF, BJ, CF, CG, CI, CM, GA, GN, GW, ML, MR, NE, SN, TD, TG).

Veröffentlicht:

Ohne internationalen Recherchenbericht und erneut zu veröffentlichen nach Erhalt des Berichts.

Zur Erklärung der Zweibuchstaben-Codes, und der anderen Abkürzungen wird auf die Erklärungen ("Guidance Notes on Codes and Abbreviations") am Anfang jeder regulären Ausgabe der PCT-Gazette verwiesen.

(54) Title: METHOD FOR THE PARALLEL DETECTION OF THE DEGREE OF METHYLATION OF GENOMIC DNA

(54) Bezeichnung: VERFAHREN ZUR PARALLELEN DETEKTION DES METHYLIERUNGSZUSTANDES VON GENOMI-

(57) Abstract: The invention relates to a method for the parallel detection of the degree of methylation of genomic DNA wherein the following the steps are performed: (a) chemical treatment at the 5' position of non-methylated cytosine bases converts said bases into uracil, thymidine or another base which exhibits hybridization behavior different to that of cytosine in a genomic DNA sample; (b) more than ten different fragments, each having less than 2000 base pairs in said chemically treated genomic DNA sample, are amplified simultaneously using synthetic oligonucleotides as a primer, whereby said primers each contain genomic sequences which are involved in gene regulation and/or transcribed and/or translated, such as those sequences which should be obtained after execution of steps (a); (c) the sequence contexts of all or a portion of the CpG dinucleotides or CpNpG trinucleotides contained in the amplified

(57) Zusammenfassung: Beschrieben ist ein Verfahren zur parallelen Detektion des Methylierungszustandes von genomischer DNA bei dem man folgende Schritte ausführt: (a) in einer genomischen DNA Probe wandelt man durch chemische Behandlung an der 5'-Position unmethylierte Cytosinbasen in Uracil, Thymidin oder eine andere vom Hybridisierungsverhalten her dem Cytosin unähnliche Base um; (b) aus dieser chemisch behandelten genomischen DNA amplifiziert man mehr als zehn unterschiedliche Fragmente, die jeweils weniger als 2000 Basenpaare lang sind, gleichzeitig durch Verwendung von synthetischen Oligonukleotiden als Primer, wobei diese Primer jeweils Sequenzen aus an der Genregulation beteiligten und/oder transkribierten und/oder translatierten genomischen Sequenzen enthalten, wie sie nach einer Behandlung gemäß Schritt (a) vorliegen würden; (c) man bestimmt den Sequenzkontext aller oder eines Teils der in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide oder CpNpG Trinukleotide.

Verfahren zur parallelen Detektion des Methylierungszustandes von genomischer DNA

Die vorliegende Erfindung betrifft ein Verfahren zur parallelen Detektion des Methylierungszustandes von genomischer DNA.

Die nach den methodischen Entwicklungen der letzten Jahre in der Molekularbiologie gut studierten Beobachtungsebenen sind die Gene selbst, die Übersetzung dieser Gene in RNA und die daraus entstehenden Proteine. Wann im Laufe der Entwicklung eines Individuums welches Gen angeschaltet wird und wie Aktivieren und Inhibieren bestimmter Gene in bestimmten Zellen und Geweben gesteuert wird, ist mit hoher Wahrscheinlichkeit mit Ausmaß und Charakter der Methylierung der Gene bzw. des Genoms korrelierbar. Insofern ist die Annahme naheliegend, daß pathogene Zustände sich in einem veränderten Methylierungsmuster einzelner Gene oder des Genoms äußern.

Stand der Technik sind Verfahren, welche das Studium von Methylierungsmustern einzelner Gene gestatten. Jüngere Fortentwicklungen dieser Methode erlauben auch die Analyse kleinster Mengen an Ausgangsmaterial. Die vorliegende Erfindung beschreibt ein Verfahren zur parallelen Detektion des Methylierungszustandes genomischer DNA Proben, wobei ausgehend von einer Probe gleichzeitig zahlreiche verschiedenene Fragmente aus an der Genregulation beteiligten oder/und transkribierten und/oder translatierten Sequenzen amplifiziert werden und anschließend der Sequenzkontext in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide untersucht wird.

5-Methylcytosin ist die häufigste kovalent modifizierte Base in der DNA eukaryotischer Zellen. Sie spielt beispielsweise eine Rolle in der Regulation der Transkription, genomischem Imprinting und in der Tumorgenese. Die Identifizierung von 5-Methylcytosin als Bestandteil genetischer Information ist daher von erheblichem Interesse. 5-Methylcytosin-Positionen können jedoch nicht durch Sequenzierung identifiziert werden, da 5-Methylcytosin das gleiche Basenpaarungsverhalten aufweist

wie Cytosin. Darüber hinaus geht bei einer PCR-Amplifikation die epigenetische Information, welche die 5-Methylcytosine tragen, vollständig verloren.

Die Modifikation der genomischen Base Cytosin zu 5'-Methylcytosin stellt den bis heute wichtigsten und best-untersuchten epigenetischen Parameter dar. Trotzdem gibt es bis heute zwar Methoden, umfassende Genotypen von Zellen und Individuen zu ermitteln, aber noch keine vergleichbaren Ansätze auch in großem Maße epigenotypische Information zu generieren und auszuwerten.

Es sind im Prinzip drei prinzipiell verschiedene Methoden bekannt, den 5-Methyl-Status eines Cytosins im Sequenzkontext zu bestimmen.

Die erste prinzipielle Methode beruht auf der Verwendung von Restriktionsendonukleasen (RE), welche "methylierungssensitiv" sind. REs zeichnen sich dadurch aus,
daß sie an einer bestimmten DNA-Sequenz, meist zwischen 4 und 8 Basen lang, einen
Schnitt in die DNA einführen. Die Position solcher Schnitte kann dann durch
Gelektrophorese, Transfer auf eine Membran und Hybridisierung nachgewiesen
werden. Methylierungssensitiv bedeutet, daß bestimmte Basen innerhalb der
Erkennungssequenz unmethyliert vorliegen müssen, damit der Schnitt erfolgen kann.
Das Bandenmuster nach einem Restriktionsschnitt und Gelektrophorese ändert sich
also je nach Methylierungsmuster der DNA. Allerdings befinden sich die wenigsten
methylierbaren CpG innerhalb von Erkennungssequenzen von REs, können also nach
dieser Methode nicht untersucht werden.

Die Empfindlichkeit dieser Methoden ist extrem niedrig (Bird, A.P., and Southern, E.M., J.Mol. Biol. 118, 27-47). Eine Variante kombiniert PCR mit dieser Methode, eine Amplifikation durch zwei auf beiden Seiten der Erkennungssequenz liegende Primer erfolgt nach einem Schnitt nur dann, wenn die Erkennungssequenz methyliert vorliegt. Die Empfindlichkeit steigt in diesem Fall auf theoretisch ein einziges Molekül der Zielsequenz, allerdings können mit hohem Aufwand nur einzelne Positionen untersucht werden (Shemer, R. et al., PNAS 93, 6371-6376). Wiederum ist Voraussetzung, daß sich die methylierbare Position innerhalb der Erkennungssequenz einer RE befindet.

Die zweite Variante beruht auf partieller chemischer Spaltung von Gesamt-DNA, nach dem Vorbild einer Maxam-Gilbert Sequenzierreaktion, Ligation von Adaptoren an die so generierten Enden, Amplifikation mit generischen Primern und Auftrennung auf einer Gelektrophorese. Mit diesem Verfahren können definierte Bereiche bis zur Größe von weniger als tausend Basenpaaren untersucht werden. Das Verfahren ist allerdings so kompliziert und unzuverlässig, daß es praktisch nicht mehr verwendet wird (Ward, C. et al., J. Biol. Chem. 265, 3030-3033).

Eine relativ neue und die mittlerweile am häufigsten angewandte Methode zur Untersuchung von DNA auf 5-Methylcytosin beruht auf der spezifischen Reaktion von Bisulphit mit Cytosin, das nach anschließender alkalischer Hydrolyse in Uracil umgewandelt wird, welches in seinem Basen-Paarungsverhalten dem Thymidin entspricht. 5-Methylcytosin wird dagegen unter diesen Bedingungen nicht modifiziert. Damit wird die ursprüngliche DNA so umgewandelt, daß Methylcytosin, welches ursprünglich durch sein Hybridisierungsverhalten vom Cytosin nicht unterschieden werden kann, jetzt durch "normale" molekularbiologische Techniken als einzig verbliebenes Cytosin beispielsweise durch Amplifikation und Hybridisierung oder Sequenzierung nachgewiesen werden kann. Alle diese Techniken beruhen auf Basenpaarung, welche jetzt voll ausgenutzt werden kann. Der Stand der Technik, was die Empfindlichkeit betrifft, wird durch ein Verfahren definiert, welches die zu untersuchende DNA in einer Agarose-Matrix einschließt, dadurch die Diffusion und Renaturierung der DNA (Bisulphit reagiert nur an einzelsträngiger DNA) verhindert und alle Fällungs- und Reinigungsschritte durch schnelle Dialyse ersetzt (Olek, A. et al., Nucl. Acids. Res. 24, 5064-5066). Mit dieser Methode können einzelne Zellen untersucht werden, was das Potential der Methode veranschaulicht. Allerdings werden bisher nur einzelne Regionen bis etwa 3000 Basenpaare Länge untersucht, eine globale Untersuchung von Zellen auf Tausende von möglichen Methylierungsereignissen ist nicht möglich. Allerdings kann auch dieses Verfahren keine sehr kleinen Fragmente aus geringen Probenmengen zuverlässig analysieren. Diese gehen trotz Diffusionsschutz durch die Matrix verloren.

Eine Übersicht über die weiteren bekannte Möglichkeiten, 5-Methylcytsosine

nachzuweisen, kann auch dem folgenden Übersichtsartikel entnommen werden: Rein, T., DePamphilis, M. L., Zorbas, H., Nucleic Acids Res. 26, 2255 (1998).

Die Bisulphit-Technik wird bisher bis auf wenige Ausnahmen (z.B. Zeschnigk, M. et al., Eur. J. Hum. Gen. 5, 94-98; Kubota T. et al., Nat. Genet. 16, I6-17) nur in der Forschung angewendet. Immer aber werden kurze, spezifische Stücke eines bekannten Gens nach einer Bisulphit-Behandlung amplifiziert und entweder komplett sequenziert (Olek, A. and Walter, J., Nat. Genet. 17, 275-276) oder einzelne Cytosin-Positionen durch eine "Primer-Extension-Reaktion" (Gonzalgo, M. L. and Jones, P.A., Nucl. Acids. Res. 25, 2529-2531) oder Enzymschnitt (Xiong, Z. and Laird, P.W., Nucl. Acids. Res. 25, 2532-2534) nachgewiesen. Zudem ist auch der Nachweis durch Hybridisierung beschrieben worden (Olek et al, WO9928498).

Gemeinsamkeiten zwischen Promotoren bestehen nicht nur im Vorkommen von TATAoder GC-Boxen sondern auch darin, für welche Transkriptionsfaktoren sie Bindestellen
besitzen und in welchem Abstand diese sich zueinander befinden. Die existierenden
Bindestellen für ein bestimmtes Protein stimmen in ihrer Sequenz nicht vollständig
überein, es finden sich aber konservierte Folgen von mindestens 4 Basen, die durch
das Einfügen von "Wobbles", d. h. Positionen, an denen sich jeweils unterschiedliche
Basen befinden, noch verlängert werden können. Des weiteren liegen diese
Bindestellen in bestimmten Abständen zueinander vor.

Die Verteilung der DNA im Interphase-Chromatin, das den größten Teil des nuklearen Volumens einnimmt, unterliegt jedoch einer ganz speziellen Ordnung. So ist die DNA an mehreren Stellen an die nukleare Matrix, eine filamentöse Struktur an der Innenseite der nuklearen Membran, angeheftet. Diese Regionen bezeichnet man als matrix attachment regions (MAR) oder scaffold attachment regions (SAR). Das Anheften hat wesentlichen Einfluß auf die Transkription bzw. die Replikation. Diese MAR-Fragmente weisen keine konservativen Sequenzen auf, bestehen allerdings zu 70% aus A bzw. T und liegen in der Nähe von cis-agierenden Regionen, die die Transkription allgemein regulieren, und Topoisomerase II-Erkennungsstellen.

WO 01/42493 PCT/DE00/04381

5

Neben Promotoren und Enhancern existieren weitere regulatorische Elemente für verschiedene Gene, sogenannte Insulators. Diese Insulators können z.B. die Wirkung des Enhancers auf den Promotor inhibieren, wenn sie zwischen Enhancer und Promotor liegen, oder aber, zwischen Heterochromatin und einem Gen gelegen, das aktive Gen vor dem Einfluß des Heterochromatins schützen. Beispiele für solche Insulators sind: 1. sogenannte LCR (locus control regions), welche aus mehreren gegenüber DNAase I hypersensitiven Stellen besteht; 2. bestimmte Sequenzen wie SCS (specialized chromatin structures) bzw. SCS', 350 bzw. 200 bp lang und hochresistent gegen Degradierung durch DNAase I und auf beiden Seiten von hypersensitiven Stellen flankiert (Abstand je 100 bp). An scs' bindet das Protein BEAF-32. Diese Insulators können auf beiden Seiten des Gens liegen.

Eine Übersicht über den Stand der Technik in der Oligomer Array Herstellung läßt sich auch einer im Januar 1999 erschienen Sonderausgabe von Nature Genetics (Nature Genetics Supplement, Volume 21, January 1999) und der dort zitierten Literatur entnehmen.

Patente, die sich allgemein auf die Verwendung von Oligomer Arrays und photolithographisches Maskendesign beziehen, sind z. B. US-A 5,837,832, US-A 5,856,174, WO-A 98/27430 und US-A 5,856,101. Zudem existieren einige Stoff- und Verfahrenspatente, welche die Verwendung photolabiler Schutzgruppen an Nukleosiden einschränken, so z. B. WO-A98/39348 und US-A 5,763,599.

Matrix-assistierte Laser Desorptions/Ionisations Massenspektrometrie (MALDI) ist eine neue, sehr leistungsfähige Entwicklung für die Analyse von Biomolekülen (Karas, M. and Hillenkamp, F. 1988. Laser desorption ionization of proteins with molecular masses exceeding 10.000 daltons. Anal. Chem. 60: 2299-2301). Ein Analytmolekül wird in eine im UV absorbierende Matrix eingebettet. Durch einen kurzen Laserpuls wird die Matrix ins Vakuum verdampft und das Analyt so unfragmentiert in die Gasphase befördert. Eine angelegte Spannung beschleunigt die Ionen in ein feldfreies Flugrohr. Auf Grund ihrer verschiedenen Massen werden Ionen unterschiedlich stark beschleunigt. Kleinere Ionen erreichen den Detektor früher als größere und die Flugzeit wird in die Masse der

Ionen umgerechnet.

Für die Abtastung eines immobilisierten DNA-Arrays sind vielfach fluoreszent markierte Sonden verwendet worden. Besonders geeignet sind für die Fluoreszenzmarkierung ist das einfache Anbringen von Cy3 und Cy5 Farbstoffen am 5'OH der jeweiligen Sonde. Die Detektion der Fluoreszenz der hybridisierten Sonden erfolgt beispielsweise über ein Konfokalmikroskop. Die Farbstoffe Cy3 und Cy5 sind, neben vielen anderen, kommerziell erhältlich.

Um die erwartete Anzahl von amplifizierten Fragmenten ausgehend von einer beliebigen Templat-DNA und zweien nicht für jeweils eine bestimmte Position spezifischen Primern zu berechnen, muß ein statistisches Modell über den Aufbau des Genoms zu Grunde gelegt werden.

Wir geben hier die Berechnung für drei Modelle an, beziehen uns allerdings in diesem Patent auf die in Modell 3 beschriebene Methode.

Modell 1:

Im einfachsten Fall wird angenommen, daß ein primärer DNA-Strang eine Zufallsfolge von vier gleich häufig vorkommenden Basen ist. Damit ergibt sich als Wahrscheinlichkeit, daß sich für einen beliebiger Primer PrimA (der Länge k) an einer gegebenen Stelle im Genom eine perfekte Basenpaarung ergibt:

$$P_a(PrimA) = 0.25^k$$
 (Modell 1 für DNA)

(diese Wahrscheinlichkeit ist für den sense- und anti-sense-Strang der DNA gleich)

Bei einer Bisulfitbehandlung der DNA werden diejenigen Cytosine durch Uracil ersetzt, die nicht zu einem methylierten CG gehören. Das Basenpaarungsverhalten des Uracils entspricht dem des Thymins. Da CG in der DNA sehr selten sind (unter zwei Prozent), kann die statistische Häufigkeit der Cs nach der Bisulfitbehandlung vernachlässigt werden. Die Wahrscheinlichkeit, daß sich für einen Primer *PrimB* (Länge k, davon a As,

7

t Ts, g Gs und c Cs) auf bisulfitbehandelter DNA eine perfekte Basenpaarung ergibt, ist unterschiedlich für einen mit Bisulfit behandelten Strang und den zugehörigen antisense Strang:

$$P_{Is}(PrimB) = 0.5^a * 0.25^t * 0.25^c * 0^g$$
 (Modell 1 für Bisulfit-DNA-Strang)
 $P_{Ia}(PrimB) = 0.25^a * 0.5^t * 0^c * 0.25^g$ (Modell 1 für anti-sense-Strang zu einem Bisulfit-DNA-Strang)

(wenn der Primer C oder G enthält, wird somit einer der Wahrscheinlichkeitswerte 0).

Modell 2:

Zählungen der Basenhäufigkeiten der DNA ergeben, daß die vier Basen in der DNA nicht gleichverteilt sind. Entsprechend kann man aus DNA-Datenbanken folgende Häufigkeiten (Wahrscheinlichkeiten für ein Vorkommen) der Basen ermitteln.

$$P_{DNA}(A) = 0.2811$$

 $P_{DNA}(T) = 0.2784$
 $P_{DNA}(C) = 0.2206$
 $P_{DNA}(G) = 0.2199$

Als Grundlage für diese Statistik (und die folgenden für Modell 2 und 3) dienen ca. 6% des Genoms vom Homo Sapiens aus High Throughput Sequencing Projekten (Datenbank "htgs" vom NIH/NCBI vom 6.9.1999). Die Gesamtmenge der Daten beträgt mehr als 1.5x10⁸ Basenpaare, was einem Schätzfehler für die Einzelwahrscheinlichkeiten kleiner 10⁻⁵ entspricht.

Mit Hilfe dieser Werte läßt sich das Modell 1 verbessern.

Damit ist die Wahrscheinlichkeit, daß sich für einen Primer PrimC (Länge k, davon a As, t Ts, g Gs und c Cs) eine perfekte Basenpaarung ergibt:

$$P_{2}(PrimC) = P_{DNA}(T)^{a} * P_{DNA}(A)' * P_{DNA}(C)^{g} * P_{DNA}(G)^{c}$$
 (Modell 3 für DNA)

Für den mit Bisulfit behandelten Strang ergeben sich folgende Wahrscheinlichkeiten unter der Annahme, daß alle CpG-Positionen methyliert sind (man erhält eine gleiche Statistik für die Bisulfitbehandlung des DNA-sense- und des DNA-antisense-Stranges):

$$P_{bDNA}(A) = 0.2811$$

$$P_{bDNA}(C) = 0.0140$$

$$P_{bDNA}(G) = 0.2199$$

$$P_{bDN4}(T) = 0.4850$$

Damit ergibt sich als Wahrscheinlichkeit, daß sich für einen Primer PrimD (Länge k, davon a As, t Ts, g Gs und c Cs) eine perfekte Basenpaarung ergibt:

$$P_{2s}(PrimD) = P_{bDNA}(T)^{a} * P_{bDNA}(A)' * P_{bDNA}(C)^{g} * P_{bDNA}(G)^{c}$$
 (Modell 3 für Bisulfit-DNA-Strang)

$$P_{2a}(PrimD) = P_{bDNA}(A)^a * P_{bDNA}(T)' * P_{bDNA}(G)^g * P_{bDNA}(C)^c \qquad \text{(Modell 3 für anti-sense-Strang zu einem Bisulfit-DNA-Strang)}$$

Modell 3:

Wesentliche Schätzfehler in Modell 2 ergeben sich vor allem bei der mit Bisulfit behandelten DNA aus der Tatsache, daß C nur noch im Kontext CG auftreten kann. Modell 3 berücksichtigt diese Eigenschaft und nimmt an, daß die primäre DNA eine Zufallsfolge mit Abhängigkeit direkt benachbarter Basen ist (Markov-Kette erster Ordnung). Die empirisch aus der Datenbank (vollständig methyliert; mit Bisulphit behandelt) ermittelten paarweisen Basenwahrscheinlichkeiten ergeben sich gleich für beide DNA-Stränge als $P_{bDM}(von;nach)$ aus der folgenden Tabelle:

Von\nach	A	С	G	T
A	0.0894	0.0033	0.0722	0.1162
С	0.0	0.0	0.0140	0.0
G	0.0603	0.0036	0.0601	0.0959
T	0.1314	0.0071	0.0736	0.2729

$$P_{bDNA}(A) = 0.2811$$

$$P_{bDNA}(C) = 0.0140$$

$$P_{hDNA}(G) = 0.2199$$

$$P_{bDNA}(T) = 0.4850$$

und für den dazu revers-komplementären Strang (durch entsprechendes Austauschen der Einträge) $P_{rbDNA}(von; nach)$

Von∖nach	A	С	G	T
A	0.2729	0.0959	0.0	0.1162
С	0.0736	0.0601	0.0140	0.0722
G	0.0071	0.0036	0.0	0.0033
Т	0.1314	0.0603	0.0	0.0894

$$P_{rbDNA}(A) = 0.4850$$
;

$$P_{rbDNA}(C) = 0.2199$$

$$P_{rbDNA}(G) = 0.0140$$

$$P_{rbDNA}(T) = 0.2811$$

Damit hängt die Wahrscheinlichkeit, daß sich für einen Primer *PrimE* (mit der Basenfolge B₁ B₂ B₃ B₄ ...; z.B. ATTG...) eine perfekte Basenpaarung ergibt, von der genauen Abfolge der Basen ab und ergibt sich als das Produkt:

$$P_{33}(PrimE) = P_{rbDNA}(B_1) \frac{P_{rbDNA}(B_1, B_2)}{P_{rbDNA}(B_1)} \frac{P_{rbDNA}(B_2, B_3)}{P_{rbDNA}(B_2)} \frac{P_{rbDNA}(B_3, B_4)}{P_{rbDNA}(B_3)} \dots$$
 (Modell 3 für

Bisulfit-DNA-Strang)

$$P_{3a}(PrimE) = P_{bDNA}(B_1) \frac{P_{bDNA}(B_1; B_2)}{P_{bDNA}(B_1)} \frac{P_{bDNA}(B_2; B_3)}{P_{bDNA}(B_2)} \frac{P_{bDNA}(B_3; B_4)}{P_{bDNA}(B_3)} \cdots \tag{Modell 3 für anti-sense-Strang zu einem Bisulfit-DNA-Strang)}$$

Berechnung der Anzahl der zu erwartenden amplifizierten Fragmente

Die mit Bisulfit behandelte DNA wird unter Benutzung einer Anzahl Primer amplifiziert. Aus Sicht des Modells besteht die DNA aus je einem sense- und einem anti-sense- Strang der Länge N Basen (alle Chromosomen werden hier zusammengefaßt). Für einen Primer *Prim* ist zu erwarten, daß er auf dem sense-Strang

$$N*P(Prim)$$

perfekte Basenpaarungen ergibt - für diese Berechnung können die Funktionen P_{1s} , P_{2s} oder P_{3s} von Modell 1, 2 oder 3 eingesetzt werden, je nach gewünschter Abschätzungsgüte. Werden mehrere Primer (PrimU, PrimV, PrimW, PrimX, etc.) gleichzeitig verwendet, ergibt sich als Wahrscheinlichkeit für eine perfekte Basenpaarung auf dem sense-Strang an einer gegebenen Position:

$$\begin{split} P_s(Primers) &= P_s(PrimU) \\ &+ (1 - P_s(PrimU)) P_s(PrimV) \\ &+ (1 - P_s(PrimU)) (1 - P_s(PrimV)) P_s(PrimW) \\ &+ (1 - P_s(PrimU)) (1 - P_s(PrimV)) (1 - P_s(PrimW)) P_s(PrimX) \\ &+ \dots \end{split}$$

Und damit als Anzahl der zu erwartenden perfekten Basenparungen mit irgendeinem der Primer

$$N * P_s(Primers)$$

Für die Bestimmung von $P_a(Primers)$ auf dem anti-sense-Strang werden die analogen Gleichungen verwendet. Ein Amplifikat entsteht genau dann, wenn bei einer perfekten Basenpaarung auf dem sense-Strang innerhalb der maximalen Fragmentlänge M ein Primer auf dem Gegenstrang eine perfekte Basenpaarung bildet. Die Wahrscheinlichkeit dafür ist

$$P_a(Primers) \sum_{i=0}^{M-2} (1 - P_a(Primers))$$

Für große M und kleine $P_{\theta}(Primers)$ kann dieses durch folgenden Ausdruck berechnet werden:

$$\frac{1 - P_a(Primers)}{\log(1 - P_a(Primers))} [(1 - P_a(Primers))^M - 1]$$

Für die Gesamtzahl F der Fragmente, die durch die Amplifikation beider Stränge zu erwarten sind, ergibt sich damit:

$$F = N * P_s(Primers) \frac{(1 - P_a(Primers))}{\log(1 - P_a(Primers))} [(1 - P_a(Primers))^M - 1]$$

$$+ N * P_a(Primers) \frac{(1 - P_s(Primers))}{\log(1 - P_s(Primers))} [(1 - P_s(Primers))^M - 1]$$

Diese Methode liefert einen präzisen Erwartungswert für die Vorhersage der Anzahl der Bindungssites bestimmter Sequenzen an ein beliebiges zuvor mit Bisulfit behandeltes genomisches DNA Fragment. Sie dient hier als Grundlage für die Berechnung der statistisch erwarteten Anzahl von Amplifikaten in einer PCR-Reaktion ausgehend von zwei Primersequenzen und einer DNA der Länge N, wobei nur die Amplifikate berücksichtigt werden, die eine Anzahl von M Nukleotiden nicht überschreiten. In diesem Patent wird davon ausgegangen, daß M den Wert 2000 hat.

Die bekannten Verfahren für den Nachweis von Cytosin Methylierungen in genomischer DNA sind prinzipiell nicht so ausgelegt, daß eine Vielzahl von Zielregionen im zu untersuchenden Genom gleichzeitig erfaßt werden. Aufgabe der vorliegenden Erfindung ist es, ein Verfahren zu schaffen, mit dem eine Probe genomischer DNA gleichzeitig an mehreren Positionen gleichzeitig auf Cytosin Methylierung hin untersucht werden kann.

Die Aufgabe wird durch die kennzeichnenden Merkmale des Anspruchs 1 gelöst. Vorteilhafte Weiterbildungen der Merkmal sind in den abhängigen Ansprüchen gekennzeichnet.

Im Unterschied zu anderen Verfahren kann nach chemischer Vorbehandlung der DNA durch Verwendung entsprechend angepaßter Primerpaare eine Amplifikation von vielen Zielregionen gleichzeitig erfolgen. Dabei ist es nicht unbedingt notwendig den Sequenzkontext aller dieser Zielregionen vorab zu kennen, da in vielen Fällen, wie nachfolgend auch beispielhaft aufgeführt, Konsensussequenzen aus der Sequenzierung verwandter Zielregionen bekannt sind, die wie unten beschrieben für das Design für bestimmte Zielregionen spezifischer oder selektiver Primerpaare eingesetzt werden können. Das Verfahren ist dann erfolgreich angewandt, wenn die Amplifikation der chemisch vorbehandelten genomischen DNA mehr Fragmente bis maximal 2000 Basenpaare Länge als statistisch zu erwarten aus den jeweils zu untersuchenden Zielregionen liefert.

Dabei wird der statistische Erwartungswert für die Anzahl dieser Fragmente über die im Stand der Technik aufgeführten Formeln berechnet. Die Anzahl der im Amplifikationsschritt hergestellten Fragmente kann dagegen mittels einer beliebigen molekularbiologischen, chemischen oder physikalischen Methode nachgewiesen werden.

Für die Durchführung der erforderlichen statistischen Betrachtungen, die auch für die unten aufgeführten Ansprüche relevant sind, werden die folgenden Werte angenommen:

Das menschliche haploide Genom enthält 3 Milliarden Basenpaare und 100.000 Gene, die wiederum im Mittel eine 2000 Basenpaare lange mRNA codieren, die Gene inklusive der Introns sind durchschnittlich 15000 Basenpaare lang. Promotoren umfassen je Gen 1000 Basenpaare durchschnittlich. Ist daher der statistische Erwartungswert für die Anzahl der Amplifikate, die ausgehend von zwei Primern in transkribierten Sequenzen liegen, zu berechnen, so ist zunächst der Erwartungswert für das Gesamtgenom nach obiger Formel (Methode 3) zu berechnen und mit dem Anteil der transkribierten Sequenzen am Gesamtgenom zu berechnen. Analog wird für Teile eines beliebigen Genoms sowie für Promotoren und translatierte Sequenzen (mRNA codierend) vorgegangen.

Die vorliegende Erfindung beschreibt somit ein Verfahren zur parallelen Detektion des Methylierungszustandes genomischer DNA. Dabei sollen mehrere Cytosin-Methylierungen in einer DNA-Probe gleichzeitig analysiert werden. Dazu werden die folgenden Verfahrensschritte nacheinander ausgeführt:

Zuerst wird eine genomische DNA Probe derart chemisch behandelt, daß an der 5'Position unmethylierte Cytosinbasen in Uracil, Thymin oder eine andere vom
Hybridisierungsverhalten her dem Cytosin unähnliche Base verwandelt werden.
Bevorzugt wird dazu die oben beschriebene Behandlung genomischer DNA mit Bisulfit
(Hydrogensulfit, Disulfit) und anschließender alkalischer Hydrolyse verwendet, die zu
einer Umwandlung nicht methylierter Cytosin-Nukleobasen in Uracil führt.

In einem zweiten Verfahrensschritt werden aus der vorbehandelten genomischen DNA mehr als zehn unterschiedliche Fragmente gleichzeitig durch Verwendung von synthetischen Oligonukleotiden als Primer amplifiziert, wobei mehr als doppelt so viele Fragmente als statistisch zu erwarten aus an der Genregulation beteiligten, transkribierten und/oder translatierten Sequenzen stammen. Dies kann mittels verschiedener Methoden erreicht werden.

In einer bevorzugten Variante des Verfahrens enthält mindestens eines der für die Amplifikation verwendeten Oligonukleotide weniger Nukleobasen als es statistisch für

eine sequenzspezifische Hybridisierung an die chemisch behandelte genomische DNA Probe erforderlich wäre, was zur Amplifikation mehrerer Fragmente gleichzeitig führen kann. Dabei ist die Gesamtzahl der in diesem Oligonukleotid enthaltenen Nukleobasen kleiner als 17. In einer besonders bevorzugten Variante des Verfahrens ist die Anzahl der in diesem Oligonukleotid enthaltenen Nukleobasen kleiner als 14.

In einer weiteren, bevorzugten Variante des Verfahrens werden für die Amplifikation mehr als 4 Oligonukleotide mit unterschiedlicher Sequenz gleichzeitig in einem Reaktionsgefäß verwendet. In einer besonders bevorzugten Varianten werden zur Herstellung eines komplexen Amplifikates mehr als 26 verschiedene Oligonukleotide gleichzeitig verwendet. In einer besonders bevorzugten Variante des Verfahrens stammt mehr als eine doppelt so hohe Anzahl, wie statistisch zu erwarten, aus an der Regulation von Genen beteiligten Genomabschnitten, z.B. Promotoren und Enhancern, stammt, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre. In einer weiteren besonders bevorzugten Variante des Verfahrens stammt mehr als eine doppelt so hohe Anzahl der amplifizierten Fragmente aus Genomabschnitten, die in mindestens einer Zelle des jeweiligen Organismus in mRNA transkribiert werden, oder aber aus nach der Transkription in mRNA gespliceten Genomabschnitten (Exons), als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre.

In einer weiteren besonders bevorzugten Variante des Verfahrens stammt mehr als eine doppelt so hohe Anzahl der amplifizierten Fragmente aus Genomabschnitten, welche für Teile einer oder mehrerer Genfamilien kodieren, oder aber sie stammen aus Genomabschnitten, welche für sogenannte "matrix attachment sites" (MARs)-charakteristische Sequenzen enthalten, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre.

In einer weiteren besonders bevorzugten Variante des Verfahrens stammt mehr als eine doppelt so hohe Anzahl der amplifizierten Fragmente aus Genomabschnitten, welche als sogenannte "boundary elements" die Verpackungsdichte des Chromatins organisieren, oder aber sie stammen aus multiple drug resistance gene" (MDR)-

WO 01/42493 PCT/DE00/04381

Promotoren oder kodierenden Regionen, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre.

In einer weiteren, besonders bevorzugten Variante des Verfahrens werden zur Amplifkation der beschriebenen Fragmente zwei Oligonukleotide oder zwei Klassen von Oligonukleotiden verwendet, von denen eines oder eine Klasse außer im Kontext CpG oder CpNpG zwar die Base C enthalten kann, nicht aber die Base G und von denen das andere oder die andere Klasse außer im Kontext CpG oder CpNpG zwar die Base G, nicht aber die Base C enthalten kann.

In einer weiteren bevorzugten Variante des Verfahrens wird die Amplifikation mittels zweier Oligonukleotide durchgeführt, von denen eines eine vier bis sechzehn Basen lange Sequenz enthält, die zu einer solchen DNA komplementär ist oder dieser entspricht, wie sie entstehen würde, wenn ein ebenso langes DNA Fragment, an welches einer der Faktoren

AhR/Arnt	aryl hydrocarbon receptor/aryl hydrocarbon receptor nuclear translocator
Arnt	aryl hydrocarbon receptor nuclear translocator
AML-1a	CBFA2; core-binding factor, runt domain, alpha subunit 2
	(acute myeloid leukemia 1; aml1 oncogene)
AP-1	activator protein-1 (AP-1); Synonyme: c-Jun
C/EBP	CCAAT/enhancer binding protein
C/EBPalpha	CCAAT/enhancer binding protein (C/EBP), alpha
C/EBPbeta	CCAAT/enhancer binding protein (C/EBP), beta
CDP	CUTL1; cut (Drosophila)-like 1 (CCAAT displacement
	protein)
CDP	CUTL1; cut (Drosophila)-like 1 (CCAAT displacement
	protein)
CDP CR1	complement component (3b/4b) receptor 1
CDP CR3	complement component (3b/4b) receptor 3
CHOP-C/EBPalpha	DDIT; DNA-damage-inducible transcript 3/CCAAT/enhancer binding protein (C/EBP), alpha
c-Myc/Max	avian myelocytomatosis viral oncogene/MYC-ASSOCIATED FACTOR X
CREB	cAMP responsive element binding protein
CRE-BP1	CYCLIC AMP RESPONSE ELEMENT-BINDING PROTEIN
	2, CREB2, CREBP1; now ATF2; activating transcription factor 2
CRE-BP1/c-Jun	activator protein-1 (AP-1); Synonyme: c-Jun

CREB	MP responsive element binding protein
E2F	E2F transcription factor (originally identified as a DNA-
	binding protein essential E1A-dependent activation of the
	adenovirus E2 promoter)
E47	transcription factor 3 (E2A immunoglobulin enhancer binding
	factors E12/E47)
E47	transcription factor 3 (E2A immune state is
	transcription factor 3 (E2A immunoglobulin enhancer binding factors E12/E47)
Egr-1	early growth response 1
Egr-2	early growth response 2 (Kray 20 (D
EĽK-1	early growth response 2 (Krox-20 (Drosophila) homolog)
	ELK1, member of ETS (environmental tobacco smoke) oncogene family
Freac-2	FKHI 6: forkhood /Droconkile) III - 2 - 50 - 10 - 1
	FKHL6; forkhead (Drosophila)-like 6; FORKHEAD-RELATED ACTIVATOR 2; FREAC2
Freac-3	FKHI 7: forkhood (Drocombile) III. 7 Formum
	FKHL7; forkhead (Drosophila)-like 7; FORKHEAD-RELATED ACTIVATOR 3; FREAC3
Freac-4	FKHI 8: forkhood (Drononhile) III . a. Familie
	FKHL8; forkhead (Drosophila)-like 8; FORKHEAD-RELATED ACTIVATOR 4; FREAC4
Freac-7	FKHI 11: forkhood (Droombile) I'll a samuru
	FKHL11; forkhead (Drosophila)-like 9; FORKHEAD- RELATED ACTIVATOR 7; FREAC7
GATA-1	GATA-hinding protoin 1/Enhance Bit is
GATA-1	GATA-binding protein 1/Enhancer-Binding Protein GATA1
GATA-1	GATA-binding protein 1/Enhancer-Binding Protein GATA1
GATA-2	GATA-binding protein 1/Enhancer-Binding Protein GATA1
GATA-3	GATA-binding protein 2/Enhancer-Binding Protein GATA2
GATA-X	GATA-binding protein 3/Enhancer-Binding Protein GATA3
HFH-3	FKHI 10: forkhead (Drosenhile) illus 40. Formula
•	FKHL10; forkhead (Drosophila)-like 10; FORKHEAD- RELATED ACTIVATOR 6; FREAC6
HNF-1	TCF1: transcription factor 1, hometical 5, D4
	TCF1; transcription factor 1, hepatic; LF-B1, hepatic nuclear factor (HNF1), albumin proximal factor
HNF-4	hepatocyte nuclear factor 4
IRF-1	interferon regulatory factor 1
ISRE	interferon-stimulated response element
Lmo2 complex	LIM domain only 2 (rhombotin-like 1)
MEF-2	MADS box transcription onbancer forther 0
	MADS box transcription enhancer factor 2, polypeptide A (myocyte enhancer factor 2A)
MEF-2	MADS box transcription enhancer factor 2, polypeptide A
	(myocyte enhancer factor 2A)
myogenin/NF-1	Myogenin (myogenic factor 4)/Neurofibromin 1;
	NEUROFIBROMATOSIS, TYPE I
MZF1	ZNF42: zinc finger protoin 42 (mustaid
	ZNF42; zinc finger protein 42 (myeloid-specific retinoic acid-responsive)
MZF1	7NF42: Zinc finger protein 40 (mg. 1)
	ZNF42; zinc finger protein 42 (myeloid-specific retinoic acid-responsive)
NF-E2	NEE2: nuclear factor (on throid of the same and the same
NF-kappaB (p50)	NFE2; nuclear factor (erythroid-derived 2), 45kD
(P00)	nuclear factor of kappa light polypeptide gene enhancer in B- cells p50 subunit
NF-kappaB (p65)	
FF (P00)	nuclear factor of kappa light polypeptide gene enhancer in B-

	·
	cells p65 subunit
NF-kappaB	nuclear factor of kappa light polypeptide gene enhancer in B-
	cells
NF-kappaB	nuclear factor of kappa light polypeptide gene enhancer in B-
	cells
NRSF	NEURON RESTRICTIVE SILENCER FACTOR; REST; RE1-
	silencing transcription factor
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
	POU2F1; POU domain, class 2, transcription factor 1
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
	POU2F1; POU domain, class 2, transcription factor 1
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
	POU2F1; POU domain, class 2, transcription factor 1
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
	POU2F1; POU domain, class 2, transcription factor 1
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
000	POU2F1; POU domain, class 2, transcription factor 1
P300	E1A (adenovirus E1A oncoprotein)-BINDING PROTEIN,
1300	300-KD
P53	tumor protein p53 (Li-Fraumeni syndrome); TP53
Pax-1	paired box gene 1
Pax-3	paired box gene 3 (Waardenburg syndrome 1)
Pax-6	paired box gene 6 (aniridia, keratitis)
Pbx 1b	pre-B-cell leukemia transcription factor
Pbx-1	pre-B-cell leukemia transcription factor 1
RORalpha2	RAR-RELATED ORPHAN RECEPTOR ALPHA; RETINOIC
2252	ACID-BINDING RECEPTOR ALPHA
RREB-1	ras responsive element binding protein 1
SP1	simian-virus-40-protein-1
SP1	simian-virus-40-protein-1
SREBP-1	sterol regulatory element binding transcription factor 1
SRF	serum response factor (c-fos serum response element-
	binding transcription factor)
SRY	sex determining region Y
STAT3	signal transducer and activator of transcription 1, 91kD
Tal-1alpha/E47	T-cell acute lymphocytic leukemia 1/transcription factor 3
·	(E2A immunoglobulin enhancer binding factors E12/E47)
TATA	cellular and viral TATA box elements
Tax/CREB	Transiently-expressed axonal glycoprotein/cAMP responsive
	element binding protein
Tax/CREB	Transiently-expressed axonal glycoprotein/cAMP responsive
147001122	element binding protein
TCF11/MafG	v-maf musculoaponeurotic fibrosarcoma (avian) oncogene
10111/1010	family, protein G
TCF11	
TOFTI	Transcription Factor 11; TCF11; NFE2L1; nuclear factor
HOE	(erythroid-derived 2)-like 1
USF	upstream stimulating factor
Whn	winged-helix nude

18

X-BP-1 YY1

X-box binding protein 1 oder ubiquitously distributed transcription factor belonging to the GLI-Kruppel class of zinc finger proteins

bindet, derart chemisch behandelt würde, daß an der 5'-Position unmethylierte Cytosinbasen in Uracil, Thymidin oder eine andere vom Hybridisierungsverhalten her dem Cytosin unähnliche Base verwandelt werden.

In einer weiteren bevorzugten Variante des Verfahrens wird die Amplifikation mittels zweier Oligonukleotide oder zweier Klassen von Oligonukleotiden durchgeführt, von denen eines oder die eine Klasse die vier bis sechzehn Basen lange Sequenz enthält, welche zu einer solchen DNA komplementär ist oder dieser entspricht, wie sie entstehen würde, wenn ein ebenso langes DNA Fragment, welches über seine Sequenz oder Sekundärstruktur die spezifische Lokalisierung von Genom/Chromatinabschnitten innerhalb des Zellkerns herbeiführen kann, derart chemisch behandelt würde, daß an der 5'-Position unmethylierte Cytosinbasen in Uracil, Thymidin oder eine andere vom Hybridisierungsverhalten her dem Cytosin unähnliche Base verwandelt werden.

In einer weiteren bevorzugten Variante des Verfahrens wird die Amplifikation mittels zweier Oligonukleotide oder zweier Klassen von Oligonukleotiden durchgeführt, von denen eines oder die eine Klasse eine der Sequenzen

TCGCGTGTA, TACACGCGA, TGTACGCGA, TCGCGTACA, TTGCGTGTT, AACACGCAA, GGTACGTAA, TTACGTACC, TCGCGTGTT, AACACGCGA, GGTACGCGA, TCGCGTACC, TTGCGTGTA, TACACGCAA, TGTACGTAA, TTACGTACA, TACGTG, CACGTA, TACGTG, CACGTA,

ATTGCGTGT, ACACGCAAT, GTACGTAAT, ATTACGTAC, ATTGCGTGA, TCACGCAAT, TTACGTAAT, ATTACGTAA, ATCGCGTGA, TCACGCGAT, TTACGCGAT, ATCGCGTAA, ATCGCGTGT, ACACGCGAT, GTACGCGAT, ATCGCGTAC, TGTGGT, ACCACA, ATTATA, TATAAT,

TGAGTTAG, CTAACTCA, TTGATTTA, TAAATCAA, TGATTTAG, CTAAATCA, TTGAGTTA, TAACTCAA,

TTTGGT, ACCAAA, ATTAAA, TTTAAT, TGTGGA, TCCACA, TTTATA, TATAAA, TTTGGA, TCCAAA, TTTAAA, TTTAAA, TGTGGT, ACCACA, ATTATA, TATAAT,

ATTAT, ATAAT, GTAAT, ATTAC, ATTGT, ACAAT, GTAAT, ATTAC,

GAAAG, CTTTC, TTTTT, AAAAA,
GTAAT, ATTAC, ATTGT, ACAAT,
GAAAT, ATTTC, ATTTT, AAAAT,
GTAAG, CTTAC, TTTGT, ACAAA,
TTAATAATCGAT, ATCGATTATTAA, ATCGATTATTGG, CCAATAATCGAT,
ATCGATTA, TAATCGAT, TAATCGAT, ATCGATTA,

ATCGATCGG, CCGATCGAT, TCGATCGAT, ATCGATCGA, ATCGATCGT, ACGATCGAT, GCGATCGAT, ATCGATCGC,

TATCGATA, TATCGATA, TATCGGTG, CACCGATA, TATTAATA, TATTAATA, TATTGGTG, CACCAATA,

GTGTAATATTT, AAATATTACAC, GGGTATTGTAT, ATACAATACCC, GTGTAATTTTT, AAAAATTACAC, GGGGATTGTAT, ATACAATCCCC, ATGTAATTTTT, AAAAATTACAT, GGGGATTGTAT, ATACAATCCCC, ATGTAATATTT, AAATATTACAT, GGGTATTGTAT, ATACAATACCC, ATTACGTGGT, ACCACGTAAT, ATTACGTGGT, ACCACGTAAT, TGACGTAA, TTACGTCA, TTACGTTA, TAACGTCA, TGACGTTA, TAACGTCA, TTACGTAA, TTACGTAA, TTACGTAA, TTACGTAA, TTACGTAA, TGACGTTA, TAACGTCA, TAACGTTA, TAACGTTA, TAACGTTA, TAACGTTA, TAACGTTA,

TGACGT, ACGTCA, GCGTTA, TAACGC, TGACGT, ACGTCA, ACGTTA, TAACGT, TTTCGCGT, ACGCGAAA, GCGCGAAA, TTTCGCGC, TTTGGCGT, ACGCCAAA, GCGTTAAA, TTTAACGC,

TAGGTGTTA, TAACACCTA, TAATATTTG, CAAATATTA, TAGGTGTTT, AAACACCTA, GAATATTTG, CAAATATTC,

GTAGGTGG, CCACCTAC, TTATTTGT, ACAAATAA, GTAGGTGT, ACACCTAC, ATATTTGT, ACAAATAT,

TGCGTGGGCGG, CCGCCCACGCA, TCGTTTACGTA, TACGTAAACGA, TGCGTGGGCGT, ACGCCCACGCA, ACGTTTACGTA, TACGTAAACGT,

TGCGTAGGCGT, ACGCCTACGCA, ACGTTTACGTA, TACGTAAACGT, TGCGTAGGCGG, CCGCCTACGCA, TCGTTTACGTA, TACGTAAACGA, ATAGGAAGT, ACTTCCTAT, ATTTTTTGT, ACAAAAAAT,

TCGGAAGT, ACTTCCGA, ATTTTCGG, CCGAAAAT, TCGGAAGT, ACTTCCGA, GTTTTCGG, CCGAAAAC, TCGGAAAT, ATTTCCGA, ATTTTCGG, CCGAAAAT, TCGGAAAT, ATTTCCGA, GTTTTCGG, CCGAAAAC, GTAAATAA, TTATTTAC, TTGTTTAT, ATAAACAA, GTAAATAAATA, TATTTATTTAC, TGTTTATTTAT, ATAAATAAACA,

AAAGTAAATA, TATTTACTTT, TGTTTATTTT, AAAATAAACA, AATGTAAATA, TATTTACATT, TGTTTATATT, AATATAAACA, TAAGTAAATA, TATTTACTTA, TGTTTATTTA, TAAATAAACA, TATGTAAATA, TATTTACATA, TGTTTATATA, TATATAAACA,

ATAAATA, TATTTAT, TGTTTAT, ATAAACA, ATAAATA, TATTTAT, TATTTAT, ATAAATA, GATA, TATC, TATT, AATA,

TAGATAA, TTATCTA, TTATTTG, CAAATAA, TTGATAA, TTATCAA, TTATTAG, CTAATAA, GATAA, TTATC, TTATT, AATAA,

GATG, CATC, TATT, AATA,

GATAG, CTATC, TTATT, AATAA, GATAAG, CTTATC, TTTATT, AATAAA,

GTTAATGATT, AATCATTAAC, AATTATTAAT, ATTAATAATT, GTTAATTATT, AATAATTAAC, AATAATTAAT, ATTAATTATT, GTTAATTAAT, ATTAATTAAC, ATTAATTAAT, ATTAATTAAT, GTTAATGAAT, ATTCATTAAC, ATTTATTAAT, ATTAATAAAT,

TAAAGTTTA, TAAACTTTA, TGAATTTTG, CAAAATTCA, TAAAGGTTA, TAACCTTTA, TGATTTTTG, CAAAAATCA,

AAAGTGAAATT, AATTTCACTTT, GGTTTTATTTT, AAAATAAAACC, AAAGCGAAATT, AATTTCGCTTT, GGTTTCGTTTT, AAAACGAAACC,

TAGTTTTATTTTTT, AAAAAAATAAAACTA, GGGAAAGTGAAATTG, CAATTTCACTTTCCC, TAGTTTTATTTTTTT, AAAAAAAATAAAACTA, GGAAAAGTGAAATTG, CAATTTCACTTTTCC, TAGTTTTTTTTTT, AAAAAAAAAAAAAAACTA, GGAAAAGAGAAAATTG, CAATTTCTCTTTTCC,

TAGTTTTTTTTT, AAAAAAAAAAAACTA, GGGAAAGAGAAATTG, CAATTTCTCTTTCCC, TAGGTG, CACCTA, TATTTG, CAAATA,

TTTTAAAAATAATTTT, AAAATTATTTTTAAAA, AGGGTTATTTTTAGAG, CTCTAAAAATAACCCT, TTTTAAAAATAACTCC, TTTTAAAAATAACTCC, TTTTAAAAATAATTTT, AAAATTATTTTTAAAA, AGAGTTATTTTTAGAG, CTCTAAAAATAACTCT, TTTTAAAAATAACTCT, TTTTAAAAATAACTCT, AAAATTATTTTTAAAA, GGGGTTATTTTTAGAG, CTCTAAAAATAACTCC,

TGTTATTAAAAATAGAAA, TTTCTATTTTTAATAACA, TTTTTATTTTTAGTAATA, TATTACTAAAAAATAAAAA, TGTTATTAAAAAATAGAAT, ATTCTATTTTTAATAACA, GTTTTATTTTAGTAATA, TATTACTAAAAATAAAAC, TTTGGTAT, ATACCAAA, GTGTTAAA, TTTAACAC GGGGA, TCCCC, TTTTT, AAAAA,

TAGGGG, CCCCTA, TTTTTA, TAAAAA, GAGGGG, CCCCTC, TTTTTT, AAAAAA, TGTTGAGTTAT, ATAACTCAACA, ATGATTTAGTA, TACTAAATCAT, TGTTGATTTAT, ATAAATCAACA, GTGAGTTAGTA, TACTAACTCAC. TGTTGAGTTAT, ATAACTCAACA, ATGATTTAGTA, TACTAAATCAT, TGTTGATTTAT, ATAAATCAACA, GTGAGTTAGTA, TACTAACTCAC, GGGGATTTT, AAAAATCCCC, GGGAATTTTT, AAAAATTCCC, GGGGATTTTT, AAAAATCCCC, GGGGATTTTT, AAAAATCCCC. GGGGATTTT, AAAAATCCCC, GGAAATTTTT, AAAAATTTCC. GGGAATTTT, AAAAATTCCC, GGAAATTTTT, AAAAATTTCC. GGGAATTTT, AAAAATTCCC, GGAAATTTTT, AAAAATTTCC. GGGATTTTT, AAAAAATCCC, GGAAAGTTTT, AAAACTTTCC. GGGAATTTT, AAAAATTCCC, GGGAATTTTT, AAAAATTCCC, GGGATTTTT, AAAAAATCCC, GGGAAGTTTT, AAAACTTCCC GGGATTTTTA, TAAAAAATCCC, TGGAAAGTTTT, AAAACTTTCCA, TTTAGTATTACGGATAGAGGT, ACCTCTATCCGTAATACTAAA, GTTTTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAAAAAC, TTTAGTATTACGGATAGAGTT, AACTCTATCCGTAATACTAAA. GGTTTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAAAACC TTTAGTATTACGGATAGCGTT, AACGCTATCCGTAATACTAAA. GGCGTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAACGCC. TTTAGTATTACGGATAGCGGT, ACCGCTATCCGTAATACTAAA. GTCGTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAACGAC.

ATATGTAAAT, ATTTACATAT, ATTTGTATAT, ATATACAAAT, TTATGTAAAT, ATTTACATAA, ATTTGTATAA, TTATACAAAT.

GAATATTTA, TAAATATTC, TGAATATTT, AAATATTCA,

GAATATGTA, TACATATTC, TGTATATTT, AAATATACA,

ATAAT, ATTAT, ATTAT, ATAAT, GTAAT, ATTAC, ATTAT, ATAAT,

AATGTAAAT, ATTTACATT, ATTTGTATT, AATACAAAT,

ATTTGTATATT, AATATACAAAT, GGTATGTAAAT, ATTTACATACC, ATTTGTATATT, AATATACAAAT, AATATGTAAAT, ATTTACATATT, ATTTGTATATT, AATATACAAAT, AGTATGTAAAT, ATTTACATACT, ATTTGTATATT, AATATACAAAT, GATATGTAAAT, ATTTACATATC,

AGGAGT, ACTCCT, ATTTTT, AAAAAT, GGGAGT, ACTCCC, ATTTTT, AAAAAT, GGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCC, GGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCC, GGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCC, AGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCT, TCGTTTCGTTTTAGATAT, ATATCTAAAACGAAACGA, ATATTTAGAGCGGAACGG, CCGTTCCGCTCTAAATAT,

CGTTACGGTT, AACCGTAACG, AATCGTGACG, CGTCACGATT, CGTTACGGTT, AACCGTAACG, GATCGTGACG, CGTCACGATC, CGTTACGTT, AAACGTAACG, AAGCGTGACG, CGTCACGCTT, CGTTACGTT, AAACGTAACG, GAGCGTGACG, CGTCACGCTC,

TTTACGTATGA, TCATACGTAAA, TTATGCGTGAA, TTCACGCATAA, TTTACGTTTGA, TCAAACGTAAA, TTAAGCGTGAA, TTCACGCTTAA, TTACGTTTTA, TAAAACGTAAA, TGAAGCGTGAA, TTCACGCTTCA, TTTACGTATTA, TAATACGTAAA, TGATGCGTGAA, TTCACGCATCA,

AATTAATTAA, TTAATTAATT, TTGATTGATT, AATCAATCAA, TATTAATTAA, TTAATTAATA, TTGATTGATG, CATCAATCAA,

TAATTAT, ATAATTA, ATGATTG, CAATCAT,

TAGGTTA, TAACCTA, TGATTTA, TAAATCA,

TTTTAAATATTTT, AAAAATATTTAAAA, GGGGGTGTTTGGGG, CCCCAAACACCCCC, TTTTAAATTATTT, AAAATAATTTAAAA, GGGGTGGTTTGGGG, CCCCAAACCACCCC, TTTTAAATTTTTT, AAAAAAAATTTAAAA, GGGGGGGTTTGGGG, CCCCAAACCCCCC, TTTTAAATTTT, AAAAATTATTTAAAA, GGGGTTGTTTGGGG, CCCCAAACACCCCC,

GAGGCGGG, CCCCGCCTC, TTTCGTTTT, AAAACGAAA,

GAGGTAGGG, CCCTACCTC, TTTTGTTTT, AAAACAAAA, AAGGCGGGG, CCCCGCCTT, TTTCGTTTT, AAAACAAAA, AAGGTAGGG, CCCTACCTT, TTTTGTTTT, AAAACAAAA.

GGGGGCGGGT, ACCCCGCCCC, ATTTCGTTTTT, AAAAACGAAAT, GGGGGCGGGGT, ACCCCGCCCCC, GTTTCGTTTTT, AAAAACGAAAC, TATTATTTTAT, ATAAAATAATA, GTGGGGTGATA, TATCACCCCAC, GATTATTTTAT, ATAAAATAATC, GTGGGGTGATT, AATCACCCCAC,

ATTACGTGAT, ATCACGTAAT, ATTACGTGAT, ATCACGTAAT, ATTACGTGAT, ATCACGTAAT, GTTACGTGAT, ATCACGTAAC.

TTTTATATGG, CCATATAAAA, TTATATAAGG, CCTTATATAA, TTATATATGG, CCATATATAA, TTATATATGG, CCATATATAA, AAATAAT, ATTATTT, GTTGTTT, AAACAAC, AAATTAA, TTAATTT, TTAGTTT, AAACTAA, AAATTAT, ATAATTT, GTAGTTT, AAACTAC, AAATAAA, TTTATTT, TTTGTTT, AAACAAA,

ATTTTCGGAAATG, CATTTCCGAAAAAT, TATTTTCGGGAAAT, ATTTCCCGAAAATA, ATTTTCGGAAAATG, CATTTCCGAAAAAT, TATTTTCGGGAAAT, ATTTCCCGAAAAATA, ATTTCCGGAAAATG, CATTTCCCGAAAAAT, TATTTTTCGGAAAAT, ATTTCCGAAAAATA, ATTTCCGGAAAATA, CACTTCCCGAAAAT, TATTTTTCGGAAAT, ATTTCCGAAAAATA.

AATAGATGTT, AACATCTATT, AATATTTGTT, AACAAATATT, AATAGATGGT, ACCATCTATT, ATTATTTGTT, AACAAATAAT,

GTATAAATA, TATTTATAC, TATTTATAT, ATATAAATA, GTATAAATG, CATTTATAC, TATTTATAT, ATATAAAAA, GTATAAAAA, TTTTTATAC, TTTTTATAT, ATATAAAAA, GTATAAAAAG, CTTTTATAC, TTTTTATAT, ATATAAAAA, TTATAAAATA, TATTTATAA, TATTTATAG, CTATAAATA, TTATAAAATG, CATTTATAAA, TATTTATAG, CTATAAAATA, TTATAAAAAA, TTTTTATAA, TTTTTATAG, CTATAAAAA, TTATAAAAAG, CTTTTATAAA, TTTTTATAG, CTATAAAAAA, GGGGGTTGACGTA, TACGTCAACCCCC, TGCGTTAATTTTT, AAAAATTAACGTA, TACGTCAACCCCC, TACGTTAATTTTT, AAAAATTAACGTA.

TGACGTATATTTTT, AAAAATATACGTCA, GGGGATATGCGTTA, TAACGCATATCCCC, TGACGTATATTTTT, AAAAATATACGTCA, GGGGGTATGCGTTA, TAACGCATACCCCC,

ATGATTTAGTA, TACTAAATCAT, TGTTGAGTTAT, ATAACTCAACA, GTTAT, ATAAC, ATGAT, ATCAT,

TTACGTGA, TCACGTAA, TTACGTGG, CCACGTAA, TTACGTGG, CCACGTAA, TTACGTGG, CCACGTAA, TTACGTGG, CCACGTAA, TTACGTGA, TCACGTAA, TTACGTGA, TCACGTAA, TTACGTGA, TCACGTAA, GACGTT, AACGTC, AGCGTT, AACGCT,

TGACGTGT, ACACGTCA, ATACGTTA, TAACGTAT, TGACGTGG, CCACGTCA, TTACGTTA, TAACGTAA, CGGTTATTTTG, CAAAATAACCG, TAAGATGGTCG oder CGACCATCTTA

enthält, welche zu einer solchen DNA komplementär ist oder dieser entspricht, wie sie entstehen würde, wenn ein ebenso langes DNA Fragment, welches über seine Sequenz oder Sekundärstruktur die spezifische Lokalisierung von Genom/Chromatinabschnitten innerhalb des Zellkerns herbeiführen kann, derart chemisch behandelt würde, daß an der 5'-Position unmethylierte Cytosinbasen in Uracil, Thymidin oder eine andere vom Hybridisierungsverhalten her dem Cytosin unähnliche Base verwandelt werden.

In einer besonders bevorzugten Variante des Verfahrens enthalten die zur Amplifikation verwendeten Oligonukleotide außer den oben definierten Konsensussequenzen mehrere Positionen, an denen entweder irgendeine der drei Basen G, A und T oder irgendeine der Basen C, A und T vorhanden sein kann.

In einer besonders bevorzugten Variante des Verfahrens enthalten die zur Amplifikation verwendeten Oligonukleotide außer einer der oben beschriebenen Konsensussequenzen nur maximal zusätzlich so viele weitere Basen, wie es zur gleichzeitigen Amplifikation von mehr als einhundert verschiedenen Fragmenten pro Reaktion aus der chemisch wie oben behandelten DNA erforderlich ist.

In einem dritten Verfahrensschritt wird nun der Sequenzkontext aller oder eines Teils der in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide oder CpNpG Trinukleotide untersucht.

In einer besonders bevorzugten Variante des Verfahrens erfolgt die Analyse durch Hybridisierung der bereits in der Amplifikation mit einem Fluoreszenzmarker versehenen Fragmente an einen Oligonukleotid- Array (DNA Chip). Der Fluoreszenzmarker kann entweder über die verwendeten Primer oder aber durch ein fluoreszenzmarkiertes Nukleotid (z. B. Cy5-dCTP, kommerziell von Amersham-Pharmacia erhältlich) eingeführt werden.

Dabei hybridisieren komplementäre Fragmente an die jeweiligen auf der Chipoberfläche immobilisierten Oligomere, nicht komplementäre Fragmente werden in einem oder mehreren Waschschritten entfernt. Die Fluoreszenz an den jeweiligen Hybridisierungsorten auf dem Chip erlaubt dann den Rückschluß auf den Sequenzkontext der in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide oder CpNpG Trinukleotide.

In einer weiteren bevorzugten Variante des Verfahrens werden die amplifizierten Fragmente auf einer Oberfläche immobilisiert und anschließend eine Hybridisierung mit einer kombinatorischen Bibiliothek von unterscheidbaren Oligonukleotid- oder PNA-Oligomer-Sonden durchgeführt. Wiederum werden nicht komplementäre Sonden durch einen oder mehrere Waschschritte entfernt. Die hybridisierten Sonden werden entweder über ihre Fluoreszenzmarker detektiert oder in einer weiteren besonders bevorzugten Variante des Verfahrens mittels Matrix-assistierter Laser-Desorptions/Ionisations Massenspektrometrie (MALDI-MS) anhand ihrer eindeutigen Masse nachgewiesen. Dabei werden die Sondenbibliotheken derart synthetisiert, daß die Masse eines jeden Bestandteils eindeutig seiner Sequenz zugeordnet werden kann.

Die Amplifikate können zudem in einer weiteren bevorzugten Variante des Verfahrens hinsichtlich Ihrer durchschnittlichen Größe durch Veränderung der Kettenverlängerungszeiten im Amplifikationsschritt beeinflußt werden. Da hier vorwiegend kleinere Fragmente (ca. 200-500 Basenpaare) untersucht werden, ist eine Verkürzung der Kettenverlängerungsschritte z. B. einer PCR sinnvoll.

In einer weiteren bevorzugten Variante des Verfahrens werden die Amplifikate durch

Gelelektrophorese aufgetrennt, und die Fragmente im gewünschten Größenbereich werden vor Ihrer Analyse ausgeschnitten. In einer weiteren besonders bevorzugten Variante werden die aus dem Gel ausgeschnittenen Amplifikate unter Verwendung des gleichen Satzes an Primern erneut amplifiziert. Dabei können dann nur noch Fragmente der gewünschten Größe entstehen, da Andere als Templat nicht mehr verfügbar sind.

Ein weiterer Gegenstand der vorleigenden Erfindung ist ein Kit, enthaltend mindestens zwei Primerpaare, Reagenzien und Hilfsstoffe für die Amplifikation und/oder Reagenzien und Hilfsmittel für die chemische Behandlung und/oder eine kombinatorische Sondenbibliothek und/oder einen Oligonukleotid-Array (DNA-Chip), soweit sie für die Durchführung des erfindungsgemäßen Verfahrens erforderlich oder dienlich sind.

Die folgenden Beispiele erläutern die Erfindung.

Beispiele:

Beispiel 1:

Primer zur bevorzugten Amplifikation von CG reichen Regionen im Humangenom

Bei den CG reichen Regionen im Humangenom handelt es sich um sogenannte CpG-islands, die eine regulatorischen Funktion besitzen. Wir definieren CpG Islands derart, dass sie mindestens 500 bp umfassen sowie einen GC-Gehalt von >50% aufweisen , ausserdem ist der Quotient CG/GC > 0,6. Unter diesen Bedingungen liegen 16 Mb als CpG Islands vor. Damit liegen etwa 0,5 % der Genomsequenz in diesen CpG islands, wenn man auch noch jeweils eine Region bis 1000 bp downstream zusätzlich betrachtet. Dieser Überlegung liegen Daten aus der Ensembl Database vom 31.10.00, Quelle Sanger Centre, zugrunde. Die dort verfügbare Sequenz umfasste ca. 3,5 GB, und für die Berechnungen wurden die Repeats maskiert.

Statistisch wäre es bei 12meren zu erwarten, dass sie nur 0,005 mal so häufig an eine der CG-reichen Regionen hybridisieren wie an eine andere beliebige Region im

Genom. Es wurden nun Primer gefunden, welche 1,8 mal häufiger an eine CG reiche Region binden. Zudem ergibt sich mit den entsprechend gefundene Reverse Primer nahezu eine Spezifität für diese CpG islands.

In diesem Beispiel sind die Primer AGTAGTAGT (Seq. ID 1) AAAACAAAACC (Seq. ID 2) und alternativ AGTAGTAGT (Seq. ID 19) und ACAAAAACTAAA (seq. ID 20). Das erste Primerpaar führt mindestens zu den Amplifikaten Seq. ID 3 bis 18, das zweite Primerpaar zu den Amplifikaten der Seq. ID 21 bis 31.

Beispiel 2:

Berechnung der Vorhersage der Anzahl von Amplifikaten in Genomischen Regionen.

Gemäß Anspruch 8 im Patent wird gezeigt mehr als doppelt so viele Amplifikate erstellen zu können, als es statistisch zu erwarten wäre nach Formel 1.

$$F = N * P_s(Primers) \frac{(P_a(Primers))}{\log(1 - P_a(Primers))} [(1 - P_a(Primers))^M - 1] + N * P_a(Primers) \frac{(P_s(Primers))}{\log(1 - P_s(Primers))} [(1 - P_s(Primers))^M - 1]$$
 Formel 1.

F gibt dabei die Anzahl der Vorhergesagten Amplifikate an, die zu erwarten sind, wenn man N Basen als Datenbasis aus dem Genom betrachtet. P ist die jeweilige Wahrscheinlichkeit für die Hybridisierung eines Primeroligonukleotids, getrennt nach Hybridisierung im Sense- und Antisense-Strang. M ist die maximal zulässige Länge der zu erwartenden Amplifikate.

Die Wahrscheinlichkeit P wird bestimmt durch eine Markov Kette erster Ordnung. Dabei wird die Annahme gemacht, dass die DNA eine Zufallsfolge in Abhängigkeit benachbarter Basen ist. Für die Berechnung einer Markovkette sind die Übergangswahrscheinlichkeiten von benachbarten Basen notwendig. Diese wurden empirisch aus 12% des assemblierten humanen Genoms, das vollständig mit Bisulfit behandelt wurde, ermittelt und in Tabelle 1 zusammengefasst. In Tabelle 2 sind die Übergangswahrscheinlichkeiten für den entsprechenden komplementär reversen

Strang angegeben. Diese ergeben sich durch einfaches Vertauschen der Einträge aus der Tabelle 1.

Tabelle 1

Von\nach	A	С	G	7
Α	0.0894	0.0033	0.0722	0.1162
С	0.0	0.0	0.0140	0.0
G	0.0603	0.0036	0.0601	0.0959
T	0.1314	0.0071	0.0736	0.2729

mit

$$P_{bDNA}(A) = 0.2811$$

$$P_{bDNA}(C) = 0.0140$$

$$P_{bDNA}(G) = 0.2199$$

$$P_{bDNA}(T) = 0.4850$$

und für den dazu revers-komplementären Strang (durch entsprechendes Austauschen der Einträge) $P_{rbDNA}(von\,;\,nach)$

Tabelle 2

Von\nach	A	С	G	7
Α	0.2729	0.0959	0.0	0.1162
С	0.0736	0.0601	0.0140	0.0722
G	0.0071	0.0036	0.0	0.0033
T	0.1314	0.0603	0.0	0.0894

$$P_{rbDNA}(A) = 0.4850$$

$$P_{rbDNA}(C) = 0.2199$$

$$P_{rbDNA}(G) = 0.0140$$

$$P_{rbDNA}(T) = 0.2811$$

Damit hängt die Wahrscheinlichkeit, dass sich für einen Primer PrimE (mit der

Basenfolge B₁ B₂ B₃ B₄ ...; z.B. ATTG...) eine perfekte Basenpaarung ergibt, von der genauen Abfolge der Basen ab und ergibt sich als das Produkt:

$$P_{3s}(PrimE) = P_{rbDNA}(B_1) \frac{P_{rbDNA}(B_1; B_2)}{P_{rbDNA}(B_1)} \frac{P_{rbDNA}(B_2; B_3)}{P_{rbDNA}(B_2)} \frac{P_{rbDNA}(B_3; B_4)}{P_{rbDNA}(B_3)} \dots$$

(Bisulfit-DNA-Strang)

$$P_{3a}(PrimE) = P_{bDNA}(B_1) \frac{P_{bDNA}(B_1; B_2)}{P_{bDNA}(B_1)} \frac{P_{bDNA}(B_2; B_3)}{P_{bDNA}(B_2)} \frac{P_{bDNA}(B_3; B_4)}{P_{bDNA}(B_3)} \dots$$

(anti-sense-Strang zu einem Bisulfit-DNA-Strang);

für einen Primer Prim auf dem sense-Strang ergeben sich

$$N * P_{s}(Prim)$$

perfekte Basenpaarungen - Werden mehrere Primer (*PrimU*, *PrimV*, *PrimW*, *PrimX*, etc.) gleichzeitig verwendet, ergibt sich als Wahrscheinlichkeit für eine perfekte Basenpaarung auf dem sense-Strang an einer gegebenen Position:

$$\begin{split} P_s(Primers) &= P_s(PrimU) \\ &+ (1 - P_s(PrimU)) P_s(PrimV) \\ &+ (1 - P_s(PrimU)) (1 - P_s(PrimV)) P_s(PrimW) \\ &+ (1 - P_s(PrimU)) (1 - P_s(PrimV)) (1 - P_s(PrimW)) P_s(PrimX) \\ &+ \end{split}$$

(PrimU, PrimV, PrimW... sind hier verschiedene Primer mit unterschiedlichen Basenpaarungen)

und damit als Anzahl der zu erwartenden perfekten Basenpaarungen mit irgendeinem der Primer

$$N*P(Primers)$$
.

Für die Bestimmung von $P_a(Primers)$ auf dem anti-sense-Strang werden die analogen Gleichungen verwendet.

Für das Beispiel mit zwei Primern (einem sense-Primer und einem antisense-Primer) ergeben sich folgende Wahrscheinlichkeiten:

P(AGTAGTAGTAGT) = 0.000000860027

P(AACAAAAACTAA) = 0.000030005828

Auf den CpG-Islands, die insgesamt ca. 30.000.000 Basen enthalten, erwartet man eine Häufigkeit von Hybridisierungen für:

AGTAGTAGT: 25.80 auf dem sense Strang

AACAAAAACTAA: 900.17 auf dem komplementär reversen Strang.

Auf den jeweils anderen Strängen können die Primer nicht hybridisieren, da auf dem sense-Strang durch die Bisulfitbehandlung keine Cs außerhalb des Kontextes CG auftreten und entsprechend komplementär auf dem antisense-Strang.

Ein Amplifikat entsteht genau dann, wenn bei einer perfekten Basenpaarung auf dem sense-Strang innerhalb der maximalen Fragmentlänge *M* ein Primer auf dem Gegenstrang eine perfekte Basenpaarung bildet, die Wahrscheinlichkeit dafür ist

$$P_a(Primers) \sum_{i=0}^{M-2} (1 - P_a(Primers))^i$$
;

für große M und kleine $P_a(Primers)$ wird dieses durch folgenden Ausdruck berechnet:

$$\frac{P_a(Primers)}{\log(1-P_a(Primers))}[(1-P_a(Primers))^M-1] ;$$

für die Gesamtzahl ${\it F}$ der Amplifikate, die durch die Amplifikation beider Stränge zu erwarten sind, ergibt sich damit

$$F = N * P_s(Primers) \frac{(P_a(Primers))}{\log(1 - P_a(Primers))} [(1 - P_a(Primers))^M - 1] \\ + N * P_a(Primers) \frac{(P_s(Primers))}{\log(1 - P_s(Primers))} [(1 - P_s(Primers))^M - 1]$$
 Formel 1

Für das oben angegebene Beispiel ergeben sich für die CpG-Islands mit 30 Mega Basen 3.0498 Amplifikate. Wir können jedoch zeigen (siehe Beispiel 1), dass man mit Primern, die für bestimmte Regionen spezifisch sind, mehr als statistisch vorhergesagte Amplifikate erzeugen kann.

Patentansprüche

- Verfahren zur parallelen Detektion des Methylierungszustandes von genomischer DNA, dadurch gekennzeichnet, daß man folgende Schritte ausführt:
 - a) in einer genomischen DNA Probe wandelt man durch chemische Behandlung an der 5'-Position unmethylierte Cytosinbasen in Uracil, Thymidin oder eine andere vom Hybridisierungsverhalten her dem Cytosin unähnliche Base um:
 - b) aus dieser chemisch behandelten genomischen DNA amplifiziert man mehr als zehn unterschiedliche Fragmente, die jeweils weniger als 2000 Basenpaare lang sind, gleichzeitig durch Verwendung von synthetischen Oligonukleotiden als Primer, wobei diese Primer jeweils Sequenzen aus an der Genregulation beteiligten und/oder transkribierten und/oder translatierten genomischen Sequenzen enthalten, wie sie nach einer Behandlung gemäß Schritt a) vorliegen würden;
 - c) man bestimmt den Sequenzkontext aller oder eines Teils der in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide oder CpNpG Trinukleotide.
- 2. Verfahren nach Anspruch 1, dadurch gekennzeichnet, daß man die chemische Behandlung mittels einer Lösung eines Bisulfits, Hydrogensulfits oder Disulfits durchführt.
- 3. Verfahren nach Anspruch 1 oder 2, dadurch gekennzeichnet, daß mindestens eines der in Schritt b) verwendeten Oligonukleotide weniger Nukleobasen enthält als es statistisch für eine sequenzspezifische Hybridisierung an die chemisch behandelte genomische DNA Probe erforderlich wäre.
- Verfahren nach einem der Ansprüche 1 bis 3, dadurch gekennzeichnet, daß mindestens eines der in Schritt b) des Anspruchs 1 verwendeten Oligonukleotide

kürzer als 18 Nukleobasen ist.

- 5. Verfahren nach einem der Ansprüche 1 bis 3, dadurch gekennzeichnet, daß mindestens eines der in Schritt b) des Anspruchs 1 verwendeten Oligonukleotide kürzer als 15 Nukleobasen ist.
- Verfahren nach Anspruch 1 oder 2, dadurch gekennzeichnet, daß man in Schritt b) des Anspruchs 1 mehr als 4 verschiedene Oligonukleotide gleichzeitig für die Amplifikation verwendet.
- 7. Verfahren nach Anspruch 1 oder 2, dadurch gekennzeichnet, daß man in Schritt b) des Anspruchs 1 mehr als 26 verschiedene Oligonukleotide gleichzeitig für die Amplifikation verwendet.
- 8. Verfahren nach einem der vorangehenden Ansprüche, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als nach berechnet nach Formel 1 aus an der Regulation von Genen beteiligten Genomabschnitten, wie Promotoren und Enhancern, stammt, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre, oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist wie berechnet nach Formel 1,

$$F = N * P_{s}(Primers) \frac{(P_{a}(Primers))}{\log(1 - P_{a}(Primers))} [(1 - P_{a}(Primers))^{M} - 1] + N * P_{a}(Primers) \frac{(P_{s}(Primers))}{\log(1 - P_{s}(Primers))} [(1 - P_{s}(Primers))^{M} - 1]$$
Formel 1

wobei man die Berechnung wie folgt durchführt:

bei der mit Bisulfit behandelten DNA kann C nur noch im Kontext CG auftreten, so wird angenommen, daß die primäre DNA eine Zufallsfolge mit Abhängigkeit direkt benachbarter Basen ist (Markov-Kette erster Ordnung); die empirisch aus der Datenbank (vollständig methyliert; mit Bisullfit behandelt) ermittelten

paarweisen Basenwahrscheinlichkeiten ergeben sich gleich für beide DNA-Stränge als $P_{bDNA}(von;nach)$ aus der folgenden Tabelle:

Von\nach	A	С	G	T
Α	0.0894	0.0033	0.0722	0.1162
С	0.0	0.0	0.0140	0.0
G	0.0603	0.0036	0.0601	0.0959
T	0.1314	0.0071	0.0736	0.2729

mit

$$P_{bDNA}(A) = 0.2811$$

$$P_{bDNA}(C) = 0.0140$$

$$P_{bDNA}(G) = 0.2199$$

$$P_{bDNA}(T) = 0.4850$$

und für den dazu revers-komplementären Strang (durch entsprechendes Austauschen der Einträge) $P_{rbDNA}(von; nach)$

Von\nach	A	С	G	T
Α	0.2729	0.0959	0.0	0.1162
С	0.0736	0.0601	0.0140	0.0722
G	0.0071	0.0036	0.0	0.0033
Т	0.1314	0.0603	0.0	0.0894

$$P_{rbDNA}(A) = 0.4850$$

$$P_{rbDNA}(C) = 0.2199$$

$$P_{rhDNA}(G) = 0.0140$$

$$P_{rbDNA}(T) = 0.2811$$

;damit hängt die Wahrscheinlichkeit, daß sich für einen Primer *PrimE* (mit der Basenfolge B₁ B₂ B₃ B₄ ...; z.B. ATTG...) eine perfekte Basenpaarung ergibt, von der genauen Abfolge der Basen ab und ergibt sich als das Produkt:

$$P_{3s}(PrimE) = P_{rbDNA}(B_1) \frac{P_{rbDNA}(B_1; B_2)}{P_{rbDNA}(B_1)} \frac{P_{rbDNA}(B_2; B_3)}{P_{rbDNA}(B_2)} \frac{P_{rbDNA}(B_3; B_4)}{P_{rbDNA}(B_3)} \dots$$

(Bisulfit-DNA-Strang)

$$P_{3a}(PrimE) = P_{bDNA}(B_1) \frac{P_{bDNA}(B_1; B_2)}{P_{bDNA}(B_1)} \frac{P_{bDNA}(B_2; B_3)}{P_{bDNA}(B_2)} \frac{P_{bDNA}(B_3; B_4)}{P_{bDNA}(B_3)} \dots$$

(anti-sense-Strang zu einem Bisulfit-DNA-Strang);

für einen Primer Prim auf dem sense-Strang ergeben sich

$$N*P_s(Prim)$$
 ;

perfekte Basenpaarungen - Werden mehrere Primer (*PrimU*, *PrimV*, *PrimW*, *PrimX*, etc.) gleichzeitig verwendet, ergibt sich als Wahrscheinlichkeit für eine perfekte Basenpaarung auf dem sense-Strang an einer gegebenen Position:

$$\begin{split} P_s(Primers) &= P_s(PrimU) \\ &+ (1 - P_s(PrimU)) P_s(PrimV) \\ &+ (1 - P_s(PrimU)) (1 - P_s(PrimV)) P_s(PrimW) \\ &+ (1 - P_s(PrimU)) (1 - P_s(PrimV)) (1 - P_s(PrimW)) P_s(PrimX) \\ &+ \dots \end{split}$$

und damit als Anzahl der zu erwartenden perfekten Basenparungen mit irgendeinem der Primer

$$N * P_s(Primers)$$
;

für die Bestimmung von $P_a(Primers)$ auf dem anti-sense-Strang werden die analogen Gleichungen verwendet; ein Amplifikat entsteht genau dann, wenn bei einer perfekten Basenpaarung auf dem sense-Strang innerhalb der maximalen Fragmentlänge M ein Primer auf dem Gegenstrang eine perfekte Basenpaarung bildet, die Wahrscheinlichkeit dafür ist

$$P_a(Primers) \sum_{i=0}^{M-2} (1 - P_a(Primers))^i$$
;

für große M und kleine $P_{a}(Primers)$ wird dieses durch folgenden Ausdruck berechnet:

$$\frac{P_a(Primers)}{\log(1-P_a(Primers))}[(1-P_a(Primers))^M-1] \;\; ;$$

für die Gesamtzahl F der Amplifikate, die durch die Amplifikation beider Stränge zu erwarten sind, ergibt sich damit

$$F = N * P_s(Primers) \frac{(P_a(Primers))}{\log(1 - P_a(Primers))} [(1 - P_a(Primers))^M - 1]$$

$$+ N * P_a(Primers) \frac{(P_s(Primers))}{\log(1 - P_s(Primers))} [(1 - P_s(Primers))^M - 1]$$
Formel 1

- 9. Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als berechnet entsprechend Anspruch 8 aus Genomabschnitten stammt, die in mindestens einer Zelle des jeweiligen Organismus in mRNA transkribiert werden, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre, oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist als berechnet entsprechend Anspruch 8.
- 10. Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als berechnet entsprechend Anspruch 8 aus nach der Transkription in mRNA gespliceten Genomabschnitten (Exons) stammt, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre, oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist als berechnet entsprechend Anspruch 8.
- 11.Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als berechnet entsprechend Anspruch 8 aus Genomabschnitten stammen, welche für Teile einer oder mehrerer Genfamilien kodieren, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre, oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist als berechnet entsprechend Anspruch 8.
- 12. Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als berechnet entsprechend Anspruch 8. aus Genomabschnitten stammen, welche für sogenannte "matrix attachment sites" (MARs)- charakteristische Sequenzen

enthalten, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre, oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist als berechnet entsprechend Anspruch 8.

- 13. Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als berechnet entsprechend Anspruch 8 aus Genomabschnitten stammen, welche als sogenannte "boundary elements" die Verpackungsdichte des Chromatins organisieren, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre, oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist als berechnet entsprechend Anspruch 8.
- 14. Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet, daß in Schritt b) des Anspruchs 1 mehr als doppelt so viele amplifizierte Fragmente als berechnet entsprechend Anspruch 8 aus "multiple drug resistance gene" (MDR)-Promotoren oder kodierenden Regionen stammen, als bei einer rein zufälligen Wahl der Oligonukleotidsequenzen zu erwarten wäre oder aber deren Anteil an den insgesamt nachweisbaren Fragmenten mehr als doppelt so hoch ist als berechnet entsprechend Anspruch 8.
- 15. Verfahren nach einem der vorangehenden Ansprüche, dadurch gekennzeichnet, daß zur Amplifkation der in Anspruch 1 beschriebenen Fragmente zwei Oligonukleotide oder zwei Klassen von Oligonukleotiden verwendet werden, von denen eines oder eine Klasse außer im Kontext CpG oder CpNpG zwar die Base C enthalten kann, nicht aber die Base G und von denen das andere oder die andere Klasse außer im Kontext CpG oder CpNpG zwar die Base G, nicht aber die Base C enthalten kann.
- 16. Verfahren nach einem der Ansprüche 1 bis 4, dadurch gekennzeichnet, daß die in Anspruch 1 beschriebene Amplifikation mittels zweier Oligonukleotide durchgeführt wird, von denen eines eine vier bis sechzehn Basen lange Sequenz enthält, welche zu einer solchen DNA komplementär ist oder dieser entspricht, wie sie entstehen

würde, wenn ein ebenso langes DNA Fragment, an welches einer der Transkriptionsfaktoren

AhR/Arnt	aryl hydrocarbon receptor/aryl hydrocarbon receptor nuclear translocator
Arnt AML-1a	aryl hydrocarbon receptor nuclear translocator CBFA2; core-binding factor, runt domain, alpha subunit 2
AP-1 C/EBP C/EBPalpha C/EBPbeta CDP	(acute myeloid leukemia 1; aml1 oncogene) activator protein-1 (AP-1); Synonyme: c-Jun CCAAT/enhancer binding protein CCAAT/enhancer binding protein (C/EBP), alpha CCAAT/enhancer binding protein (C/EBP), beta CUTL1; cut (Drosophila)-like 1 (CCAAT displacement
CDP	protein) CUTL1; cut (Drosophila)-like 1 (CCAAT displacement
CDP CR1 CDP CR3 CHOP-C/EBPalpha	protein) complement component (3b/4b) receptor 1 complement component (3b/4b) receptor 3 DDIT; DNA-damage-inducible transcript 3/CCAAT/enhancer
c-Myc/Max	binding protein (C/EBP), alpha avian myelocytomatosis viral oncogene/MYC-ASSOCIATED FACTOR X
CREB CRE-BP1	cAMP responsive element binding protein CYCLIC AMP RESPONSE ELEMENT-BINDING PROTEIN 2, CREB2, CREBP1; now ATF2; activating transcription factor 2
CRE-BP1/c-Jun CREB E2F	activator protein-1 (AP-1); Synonyme: c-Jun MP responsive element binding protein E2F transcription factor (originally identified as a DNA- binding protein essential E1A-dependent activation of the adenovirus E2 promoter)
E47	transcription factor 3 (E2A immunoglobulin enhancer binding factors E12/E47)
E47	transcription factor 3 (E2A immunoglobulin enhancer binding factors E12/E47)
Egr-1 Egr-2 ELK-1	early growth response 1 early growth response 2 (Krox-20 (Drosophila) homolog) ELK1, member of ETS (environmental tobacco smoke) oncogene family
Freac-2	FKHL6; forkhead (Drosophila)-like 6; FORKHEAD-RELATED ACTIVATOR 2; FREAC2
Freac-3	FKHL7; forkhead (Drosophila)-like 7; FORKHEAD-RELATED ACTIVATOR 3; FREAC3
Freac-4	FKHL8; forkhead (Drosophila)-like 8; FORKHEAD-RELATED ACTIVATOR 4; FREAC4
Freac-7	FKHL11; forkhead (Drosophila)-like 9; FORKHEAD- RELATED ACTIVATOR 7; FREAC7

•	
GATA-1	GATA-hinding protoin 1/Enhance Division
GATA-1	GATA-binding protein 1/Enhancer-Binding Protein GATA1
GATA-1	On A-binding protein 1/Enhancer-Rinding Protein CATA4
	OATA-DINGING Protein 1/Enhancer-Rinding Protein CATA4
GATA-2	On A-billully brotein 2/Enhancer-Rinding Brotoin CATAG
GATA-3	GATA-binding protein 3/Enhancer-Binding Protein GATA3
GATA-X	5 Freedom of Enhancer-Binding Protein GATA3
· HFH-3	FKHL10; forkhead (Drosophila)-like 10; FORKHEAD-
	RELATED ACTIVATOR C. EDEACO
HNF-1	RELATED ACTIVATOR 6; FREAC6
	TCF1; transcription factor 1, hepatic; LF-B1, hepatic nuclear
HNF-4	racioi-(Fine I), albumin proximal factor
	nepatocyte nuclear factor 4
IRF-1	interferon regulatory factor 1
ISRE	Interferon-stimulated response element
Lmo2 complex	LIM domain only 2 (rhombotin-like 1)
MEF-2	MADS box transcription enhancer factor 2, polypeptide A
•	(myocyte enhancer factor 2A)
MEF-2	MADS have transportation and a
· · · · · · · · · · · · · · · · · · ·	MADS box transcription enhancer factor 2, polypeptide A
.myogenin/NF-1	(myocyte enhancer factor 2A)
;inyogeriii//qr = r	Myogenin (myogenic factor 4)/Neurofibromin 1;
NA7E4	NEURUFIBROMATOSIS TYPE I
MZF1	ZNF42; zinc finger protein 42 (myeloid-specific retinoic acid-
	responsive)
MZF1	ZNF42; zinc finger protein 42 (myeloid-specific retinoic acid-
•	responsive)
NF-E2	NFE2; nuclear factor (erythroid-derived 2), 45kD
NF-kappaB (p50)	nuclear factor of kappa light nature and the
(nuclear factor of kappa light polypeptide gene enhancer in B- cells p50 subunit
NF-kappaB (p65)	nuclear factor of transmit at a second suburity
: паррав (роо)	nuclear factor of kappa light polypeptide gene enhancer in B-
NF-kappaB	
ти -каррав	nuclear factor of kappa light polypeptide gene enhancer in B-
ME Isaara D	CONS
NF-kappaB	nuclear factor of kappa light polypeptide gene enhancer in B-
·	00110
NRSF	NEURON RESTRICTIVE SILENCER FACTOR; REST; RE1-
	silencing transcription factor
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
	POLIZET: POLI domain place 0 4
Oct-1	POU2F1; POU domain, class 2, transcription factor 1
	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
Oct-1	POU2F1; POU domain, class 2, transcription factor 1
OCI-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1.
0.4	POUZF1; POU domain, class 2, transcription factor 1
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1
•	POU2F1; POU domain, class 2, transcription factor 1
Oct-1	OCTAMER-BINDING TRANSCRIPTION FACTOR 1;
,	POUZE1: POU domain, plane 2, terres 1: 11
P300	POU2F1; POU domain, class 2, transcription factor 1
	E1A (adenovirus E1A oncoprotein)-BINDING PROTEIN,
P53	300-KD
1 00	tumor protein p53 (Li-Fraumeni syndrome); TP53

Pax-1	paired box gene 1
Pax-3	paired box gene 3 (Waardenburg syndrome 1)
Pax-6	paired box gene 6 (aniridia, keratitis)
Pbx 1b	pre-B-cell leukemia transcription factor
Pbx-1	pre-B-cell leukemia transcription factor 1
RORalpha2	RAR-RELATED ORPHAN RECEPTOR ALPHA; RETINOIC
•	ACID-BINDING RECEPTOR ALPHA
RREB-1	ras responsive element binding protein 1
SP1	simian-virus-40-protein-1
SP1	simian-virus-40-protein-1
SREBP-1	sterol regulatory element binding transcription factor 1
SRF	serum response factor (c-fos serum response element-
	binding transcription factor)
SRY	sex determining region Y
STAT3	signal transducer and activator of transcription 1, 91kD
Tal-1alpha/E47	T-cell acute lymphocytic leukemia 1/transcription factor 3
	(E2A immunoglobulin enhancer binding factors E12/E47)
TATA	cellular and viral TATA box elements
Tax/CREB	Transiently-expressed axonal glycoprotein/cAMP responsive
	element binding protein
Tax/CREB	Transiently-expressed axonal glycoprotein/cAMP responsive
	element binding protein
TCF11/MafG	v-maf musculoaponeurotic fibrosarcoma (avian) oncogene
	family, protein G
TCF11	Transcription Factor 11; TCF11; NFE2L1; nuclear factor
	(erythroid-derived 2)-like 1
USF	upstream stimulating factor
Whn	winged-helix nude
X-BP-1	X-box binding protein 1 oder
YY1	ubiquitously distributed transcription factor belonging to
	theGLI-Kruppel class of zinc finger proteins

bindet, einer chemischen Behandlung gemäß Anspruch 1 unterzogen würde.

17. Verfahren nach einem der Ansprüche 1 bis 4, dadurch gekennzeichnet, daß man die in Anspruch 1 beschriebene Amplifikation mittels zweier Oligonukleotide durchführt, von denen eines die eine vier bis sechzehn Basen lange Sequenz enthält, welche zu einer solchen DNA komplementär ist oder dieser entspricht, wie sie entstehen würde, wenn ein ebenso langes DNA Fragment, welches über seine Sequenz oder Sekundärstruktur die spezifische Lokalisierung von Genom/Chromatinabschnitten innerhalb des Zellkerns herbeiführen kann, einer chemischen Behandlung gemäß Anspruch 1 unterzogen würde.

18 Verfahren nach einem der Ansprüche 1 bis 4, dadurch gekennzeichnet, daß die in Anspruch 1 beschriebene Amplifikation mittels zweier Oligonukleotide durchgeführt wird, von denen mindestens eine der Sequenzen (von 5 nach 3)

TCGCGTGTA, TACACGCGA, TGTACGCGA, TCGCGTACA, TTGCGTGTT, AACACGCAA, GGTACGTAA, TTACGTACC, TCGCGTGTT, AACACGCGA, GGTACGCGA, TCGCGTACC, TTGCGTGTA, TACACGCAA, TGTACGTAA, TTACGTACA, TACGTG, CACGTA, TACGTG, CACGTA,

ATTGCGTGT, ACACGCAAT, GTACGTAAT, ATTACGTAC, ATTGCGTGA, TCACGCAAT, TTACGTAAT, ATTACGTAA, ATCGCGTGA, TCACGCGAT, TTACGCGAT, ATCGCGTAA, ATCGCGTGT, ACACGCGAT, GTACGCGAT, ATCGCGTAC, TGTGGT, ACCACA, ATTATA, TATAAT,

TGAGTTAG, CTAACTCA, TTGATTTA, TAAATCAA, TGATTTAG, CTAAATCA, TTGAGTTA, TAACTCAA,

TTTGGT, ACCAAA, ATTAAA, TTTAAT, TGTGGA, TCCACA, TTTATA, TATAAA, TTTGGA, TCCAAA, TTTAAA, TTTAAA, TGTGGT, ACCACA, ATTATA, TATAAT,

ATTAT, ATAAT, GTAAT, ATTAC, ATTGT, ACAAT, GTAAT, ATTAC,

GAAAG, CTTTC, TTTTT, AAAAA, GTAAT, ATTAC, ATTGT, ACAAT, GAAAT, ATTTC, ATTTT, AAAAT, GTAAG, CTTAC, TTTGT, ACAAA, TTAATAATCGAT, ATCGATTATTAA, ATCGATTATTGG, CCAATAATCGAT, ATCGATTA, TAATCGAT, TAATCGAT, ATCGATTA,

ATCGATCGG, CCGATCGAT, TCGATCGAT, ATCGATCGA, ATCGATCGAT, ACGATCGAT, GCGATCGAT, ATCGATCGC,

TATCGATA, TATCGATA, TATCGGTG, CACCGATA, TATTAATA, TATTAATA, TATTGGTG, CACCAATA,

GTGTAATATTT, AAATATTACAC, GGGTATTGTAT, ATACAATACCC, GTGTAATTTTT, AAAAATTACAC, GGGGATTGTAT, ATACAATCCCC, ATGTAATTTTT, AAAAATTACAT, GGGGATTGTAT, ATACAATCCCC, ATGTAATATTT, AAATATTACAT, GGGTATTGTAT, ATACAATACCC, ATTACGTGGT, ACCACGTAAT, ATTACGTGGT, ACCACGTAAT,

TGACGTAA, TTACGTCA, TTACGTTA, TAACGTAA, TGACGTTA, TAACGTCA, TGACGTAA, TTACGTAA, TTACGTAA, TTACGTAA, TGACGTTA, TAACGTCA, TAACGTTA, TAACGTTA,

TGACGT, ACGTCA, GCGTTA, TAACGC, TGACGT, ACGTCA, ACGTTA, TAACGT, TTTCGCGT, ACGCGAAA, GCGCGAAA, TTTCGCGC, TTTGGCGT, ACGCCAAA, GCGTTAAA, TTTAACGC,

TAGGTGTTA, TAACACCTA, TAATATTTG, CAAATATTA, TAGGTGTTT, AAACACCTA, GAATATTTG, CAAATATTC,

GTAGGTGG, CCACCTAC, TTATTTGT, ACAAATAA, GTAGGTGT, ACACCTAC, ATATTTGT, ACAAATAT,

TGCGTGGGCGG, CCGCCCACGCA, TCGTTTACGTA, TACGTAAACGA, TGCGTGGGCGT, ACGCCCACGCA, ACGTTTACGTA, TACGTAAACGT.

TGCGTAGGCGT, ACGCCTACGCA, ACGTTTACGTA, TACGTAAACGT, TGCGTAGGCGG, CCGCCTACGCA, TCGTTTACGTA, TACGTAAACGA, ATAGGAAGT, ACTTCCTAT, ATTTTTTGT, ACAAAAAAT.

TCGGAAGT, ACTTCCGA, ATTTTCGG, CCGAAAAT, TCGGAAGT, ACTTCCGA, GTTTTCGG, CCGAAAAC, TCGGAAAT, ATTTCCGA, ATTTTCGG, CCGAAAAT, TCGGAAAT, ATTTCCGA, GTTTTCGG, CCGAAAAC, GTAAATAA, TTATTTAC, TTGTTTAT, ATAAACAA, GTAAATAAATA, TATTTATTTAC, TGTTTATTTAT, ATAAATAAACA,

AAAGTAAATA, TATTTACTTT, TGTTTATTTT, AAAATAAACA, AATGTAAATA, TATTTACATT, TGTTTATATT, AATATAAACA, TAAGTAAATA, TATTTACTTA, TGTTTATTTA, TAAATAAACA, TATGTAAATA, TATTTACATA, TGTTTATATA, TATATAAACA,

ATAAATA, TATTTAT, TGTTTAT, ATAAACA, ATAAATA, TATTTAT, TATTTAT, ATAAATA, GATA, TATC, TATT, AATA,

TAGATAA, TTATCTA, TTATTTG, CAAATAA, TTGATAA, TTATCAA, TTATTAG, CTAATAA, GATAA, TTATC, TTATT, AATAA.

GATG, CATC, TATT, AATA,

GATAG, CTATC, TTATT, AATAA, GATAAG, CTTATC, TTTATT, AATAAA,

GTTAATGATT, AATCATTAAC, AATTATTAAT, ATTAATAATT, GTTAATTATT, AATAATTAAC, AATAATTAAT, ATTAATTATT, GTTAATTAAT, ATTAATTAAC, ATTAATTAAT, ATTAATTAAT, GTTAATGAAT, ATTCATTAAC, ATTTATTAAT, ATTAATAAAT,

TAAAGTTTA, TAAACTTTA, TGAATTTTG, CAAAATTCA, TAAAGGTTA, TAACCTTTA, TGATTTTTG, CAAAAATCA,

AAAGTGAAATT, AATTTCACTTT, GGTTTTATTTT, AAAATAAAACC, AAAGCGAAATT, AATTTCGCTTT, GGTTTCGTTTT, AAAACGAAACC,

TAGTTTTATTTTTT, AAAAAAAATAAAACTA, GGGAAAGTGAAATTG, CAATTTCACTTTCCC, TAGTTTTATTTTTTT, AAAAAAAATAAAACTA, GGAAAAGTGAAATTG, CAATTTCACTTTTCC, TAGTTTTTTTTTTT, AAAAAAAAAAAAAACTA, GGAAAAGAGAAATTG, CAATTTCTCTTTTCC, TAGTTTTTTTTTTT, AAAAAAAAAAAAAACTA, GGGAAAGAGAAATTG, CAATTTCTCTTTCCC, TAGGTG, CACCTA, TATTTG, CAAATA.

TTTTAAAAATAATTTT, AAAATTATTTTTAAAA, AGGGTTATTTTTAGAG, CTCTAAAAATAACCCT, TTTTAAAAATAACTCC, TTTTAAAAATAACTCC, TTTTAAAAATAATTTT, AAAATTATTTTTAAAA, AGAGTTATTTTTAGAG, CTCTAAAAATAACTCT, AAAATTATTTTTAAAA, AGAGTTATTTTTAGAG, CTCTAAAAATAACTCT, TTTTAAAAATAACTCT, CTCTAAAAATAACCCC,

TGTTATTAAAAATAGAAA, TTTCTATTTTTAATAACA, TTTTTATTTTTAGTAATA, TATTACTAAAAATAAAAA, TGTTATTAAAAAATAGAAT, ATTCTATTTTTAATAACA, GTTTTATTTTTAGTAATA, TATTACTAAAAATAAAAC, TTTGGTAT, ATACCAAA, GTGTTAAA, TTTAACAC GGGGA, TCCCC, TTTTT, AAAAA,

TAGGGG, CCCCTA, TTTTTA, TAAAAA,
GAGGGG, CCCCTC, TTTTTT, AAAAAA,
TGTTGAGTTAT, ATAACTCAACA, ATGATTTAGTA, TACTAAATCAT,
TGTTGATTTAT, ATAAATCAACA, GTGAGTTAGTA, TACTAACTCAC,
TGTTGAGTTAT, ATAACTCAACA, ATGATTTAGTA, TACTAAATCAT,
TGTTGATTTAT, ATAAATCAACA, GTGAGTTAGTA, TACTAACTCAC,

GGGGATTTTT, AAAAATCCCC, GGGAATTTTT, AAAAATTCCC, GGGGATTTTT, AAAAATCCCC, GGGGATTTTT, AAAAATCCCC, GGGGATTTTT, AAAAATCCCC, GGAAATTTTT, AAAAATTTCC. GGGAATTTT, AAAAATTCCC, GGAAATTTTT, AAAAATTTCC, GGGAATTTTT, AAAAATTCCC, GGAAATTTTT, AAAAATTTCC, GGGATTTTT, AAAAAATCCC, GGAAAGTTTT, AAAACTTTCC, GGGAATTTTT, AAAAATTCCC, GGGAATTTTT, AAAAATTCCC, GGGATTTTT, AAAAAATCCC, GGGAAGTTTT, AAAACTTCCC, GGGATTTTTA, TAAAAAATCCC, TGGAAAGTTTT, AAAACTTTCCA, TTTAGTATTACGGATAGAGGT, ACCTCTATCCGTAATACTAAA, GTTTTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAAAAAC, TTTAGTATTACGGATAGAGTT, AACTCTATCCGTAATACTAAA. GGTTTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAAAACC, TTTAGTATTACGGATAGCGTT, AACGCTATCCGTAATACTAAA, GGCGTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAACGCC. TTTAGTATTACGGATAGCGGT, ACCGCTATCCGTAATACTAAA, GTCGTTGTTCGTGGTGTTGAA, TTCAACACCACGAACAACGAC.

ATATGTAAAT, ATTTACATAT, ATTTGTATAT, ATATACAAAT, TTATGTAAAT, ATTTACAAAA, ATTTGTATAA, TTATACAAAT,

GAATATTTA, TAAATATTC, TGAATATTT, AAATATTCA, GAATATGTA, TACATATTC, TGTATATTT, AAATATACA,

ATAAT, ATTAT, ATAAT, GTAAT, ATAAT, ATTAC, ATTAT, ATAAT,

AATGTAAAT, ATTTACATT, ATTTGTATT, AATACAAAT,

ATTTGTATATT, AATATACAAAT, GGTATGTAAAT, ATTTACATACC, ATTTGTATATT, AATATACAAAT, AATATGTAAAT, ATTTACATACT, ATTTGTATATT, AATATACAAAT, AGTATGTAAAT, ATTTACATACT, ATTTGTATATT, AATATACAAAT, GATATGTAAAT, ATTTACATATC,

AGGAGT, ACTCCT, ATTTTT, AAAAAT,
GGGAGT, ACTCCC, ATTTTT, AAAAAT,
GGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCC,
GGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCC,
GGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCC,
AGATATGTTCGGGTATGTTT, AAACATACCCGAACATATCT,
TCGTTTCGTTTTAGATAT, ATATCTAAAACGAAACGA,
ATATTTAGAGCGGAACGG, CCGTTCCGCTCTAAATAT,

CGTTACGGTT, AACCGTAACG, AATCGTGACG, CGTCACGATT, CGTTACGGTT, AACCGTAACG, GATCGTGACG, CGTCACGATC, CGTTACGTTT, AAACGTAACG, AAGCGTGACG, CGTCACGCTT, CGTTACGTTT, AAACGTAACG, GAGCGTGACG, CGTCACGCTC.

TTTACGTATGA, TCATACGTAAA, TTATGCGTGAA, TTCACGCATAA, TTTACGTTTGA, TCAAACGTAAA, TTAAGCGTGAA, TTCACGCTTAA, TTTACGTTTTA, TAAAACGTAAA, TGAAGCGTGAA, TTCACGCTTCA, TTTACGTATTA, TAATACGTAAA, TGATGCGTGAA, TTCACGCATCA,

AATTAATTAA, TTAATTAATT, TTGATTGATT, AATCAATCAA, TATTAATTAA, TTAATTAATA, TTGATTGATG, CATCAATCAA,

TAATTAT, ATAATTA, ATGATTG, CAATCAT,

TAGGTTA, TAACCTA, TGATTTA, TAAATCA,

TTTTAAATATTTT, AAAAATATTTAAAA, GGGGGTGTTTGGGG, CCCCAAACACCCCC, TTTTAAATTATTT, AAAATAATTTAAAA, GGGGTGGTTTGGGG, CCCCAAACCACCCC, TTTTAAATTTTTT, AAAAAAAATTTAAAA, GGGGGGGTTTGGGG, CCCCAAACCCCCC, TTTTAAATTTTT, AAAATTATTTAAAA, GGGGTTGTTTGGGG, CCCCAAACACCCCCC,

GAGGCGGGG, CCCCGCCTC, TTTCGTTTT, AAAACGAAA, GAGGTAGGG, CCCTACCTC, TTTTGTTTT, AAAACAAAA, AAGGCGGGG, CCCCGCCTT, TTTCGTTTT, AAAACGAAA, AAGGTAGGG, CCCTACCTT, TTTTGTTTT, AAAACAAAA,

GGGGGCGGGT, ACCCCGCCCC, ATTTCGTTTTT, AAAAACGAAAT, GGGGGCGGGGT, ACCCCGCCCCC, GTTTCGTTTTT, AAAAACGAAAC, TATTATTTTAT, ATAAAATAATA, GTGGGGTGATA, TATCACCCCAC, GATTATTTTAT, ATAAAATAATC, GTGGGGTGATT, AATCACCCCAC,

ATTACGTGAT, ATCACGTAAT, ATTACGTGAT, ATCACGTAAT, ATTACGTGAT, ATCACGTAAT, GTTACGTGAT, ATCACGTAAC,

TTTTATATGG, CCATATAAAA, TTATATAAGG, CCTTATATAA, TTATATATGG, CCATATATAA, TTATATATGG, CCATATATAA, AAATAAT, ATTATTT, GTTGTTT, AAACAAC, AAATTAA, TTAATTT, TTAGTTT, AAACTAA, AAATTAT, ATAATTT, GTAGTTT, AAACTAC, AAATAAA, TTTATTT, TTTGTTT, AAACAAA,

ATTTTCGGAAATG, CATTTCCGAAAAAT, TATTTTCGGGAAAT, ATTTCCCGAAAATA, ATTTTCGGAAAATG, CATTTCCGAAAAAT, TATTTTCGGGAAAT, ATTTCCCGAAAAATA, ATTTCCGGAAAATA, CATTTCCCGAAAAT, TATTTTCGGAAAAT, ATTTCCGAAAAATA, ATTTCCGGAAAATA, CACTTCCCGAAAAT, TATTTTCGGAAAT, ATTTCCGGAAAGTG, CACTTCCCGAAAAT, TATTTTTCGGAAAT, ATTTTCGGGAAAT,

ATTTCCGAAAAATA,

AATAGATGTT, AACATCTATT, AATATTTGTT, AACAAATATT, AATAGATGGT, ACCATCTATT, ATTATTTGTT, AACAAATAAT,

GTATAAATA, TATTTATAC, TATTTATAT, ATATAAATA, GTATAAATG, CATTTATAC, TATTTATAT, ATATAAATA, GTATAAAAA, TTTTTATAC, TTTTTATAT, ATATAAAAA, GTATAAAAA, CTTTTATAC, TTTTTATAT, ATATAAAAA, TTATAAAATA, TATTTATAG, CTATAAATA, TTATAAATG, CATTTATAA, TATTTATAG, CTATAAATA, TTATAAAAA, TTTTTATAA, TTTTTATAG, CTATAAAAA, TTATAAAAAA, TTTTTATAG, CTATAAAAA, GGGGGTTGACGTA, TACGTCAACCCCC, TGCGTTAATTTTT, AAAAATTAACGTA, TACGTCAACCCCC, TACGTTAATTTTT, AAAAATTAACGTA,

TGACGTATATTTTT, AAAAATATACGTCA, GGGGATATGCGTTA, TAACGCATATCCCC, TGACGTATATTTTT, AAAAATATACGTCA, GGGGGTATGCGTTA, TAACGCATACCCCC, ATGATTAGTA, TACTAAATCAT, TGTTGAGTTAT, ATAACTCAACA, GTTAT, ATAAC, ATGAT, ATCAT,

TTACGTGA, TCACGTAA, TTACGTGG, CCACGTAA, TTACGTGG, CCACGTAA, TTACGTGG, CCACGTAA, TTACGTGG, CCACGTAA, TTACGTGA, TCACGTAA, TTACGTGA, TCACGTAA, TTACGTGA, TCACGTAA, GACGTT, AACGTC, AGCGTT, AACGCT,

TGACGTGT, ACACGTCA, ATACGTTA, TAACGTAT,
TGACGTGG, CCACGTCA, TTACGTTA, TAACGTAA,
CGGTTATTTTG, CAAAATAACCG, TAAGATGGTCG oder CGACCATCTTA

enthält, welche zu einer solchen DNA komplementär ist oder dieser entspricht, wie sie entstehen würde, wenn ein ebenso langes DNA Fragment, welches über seine Sequenz oder Sekundärstruktur die spezifische Lokalisierung von Genom/Chromatinabschnitten innerhalb des Zellkerns herbeiführen kann, einer chemischen Behandlung gemäß Anspruch 1 unterzogen würde.

19. Verfahren nach einem der Ansprüche 16 bis 18, dadurch gekennzeichnet, daß die zur Amplifikation verwendeten Oligonukleotide außer den in den Ansprüchen 16 bis 18 definierten Konsensussequenzen mehrere Positionen enthalten, an denen

entweder irgendeine der drei Basen G, A und T oder irgendeine der Basen C, A und T vorhanden sein kann.

- 20. Verfahren nach Anspruch 19, dadurch gekennzeichnet, daß die zur Amplifikation verwendeten Oligonukleotide außer einer der in den Anspruch 18 beschriebenen Konsensussequenzen nur maximal zusätzlich so viele weitere Basen enthalten, wie es zur gleichzeitigen Amplifikation von mehr als einhundert verschiedenen Fragmenten pro Reaktion aus der chemisch behandelten DNA, berechnet entsprechend Anspruch 8, erforderlich ist.
- 21 Verfahren nach einem der vorangehenden Ansprüche dadurch gekennzeichnet, daß die Untersuchung des Sequenzkontextes aller oder eines Teils der in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide oder CpNpG Trinukleotide gemäß Anspruch 1 c) durch Hybridisierung der bereits in der Amplifikation mit einem Fluoreszenzmarker versehenen Fragmente an einen Oligonukleotid- Array (DNA Chip) erfolgt.
- 22. Verfahren nach einem der Ansprüche 1 bis 20 dadurch gekennzeichnet, daß die amplifizierten Fragmente auf einer Oberfläche immobilisiert und anschließend eine Hybridisierung mit einer kombinatorischen Bibiliothek von unterscheidbaren Oligonukleotid- oder PNA-Oligomer-Sonden durchgeführt wird.
- 23. Verfahren nach Anspruch 22 dadurch gekennzeichnet, daß die Sonden mittels Matrix-assistierter Laser-Desorptions/Ionisations Massenspektrometrie (MALDI-MS) anhand ihrer eindeutigen Masse nachgewiesen werden und damit der Sequenzkontext aller oder eines Teils der in den amplifizierten Fragmenten enthaltenen CpG Dinukleotide oder CpNpG Trinukleotide entschlüsselt wird.
- 24. Verfahren nach einem der vorangehenden Ansprüche, dadurch gekennzeichnet, daß die Amplifikation wie beschrieben in Schritt b) des Anspruchs 1 durch eine Polymerase Kettenreaktion ausgeführt wird, in der die Größe der amplifizierten Fragmente mittels auf weniger als 30 s verkürzter Kettenverlängerungsschritte

begrenzt wird.

- 25. Verfahren nach einem der vorangehenden Ansprüche, dadurch gekennzeichnet, daß nach der Amplifikation gemäß Schritt b) des Anspruchs 1 die Produkte durch Gelelektrophorese aufgetrennt werden und die Fragmente, die kleiner als 2000 Basenpaare oder kleiner als ein beliebiger Grenzwert unterhalb von 2000 Basenpaaren sind, durch Ausschneiden von den anderen Produkten der Amplifikation vor der Auswertung gemäß Schritt c) des Anspruchs 1 abgetrennt werden.
- 26. Verfahren nach Anspruch 25 dadurch gekennzeichnet, daß nach der Abtrennung von Amplifikaten bestimmter Größe diese vor der Durchführung des Schrittes c) des Anspruchs 1 nochmals amplifiziert werden.
- 27.Kit, enthaltend mindestens zwei Primerpaare, Reagenzien und Hilfsstoffe für die Amplifikation und/oder Reagenzien und Hilfsmittel für die chemische Behandlung gemäß Anspruch 1 a) und/oder eine kombinatorische Sondenbibliothek und/oder einen Oligonukleotid-Array (DNA-Chip), soweit sie für die Durchführung des erfindungsgemäßen Verfahrens erforderlich oder dienlich sind.

WO 01/42493

PCT/DE00/04381

1

SEQUENZPROTOKOLL

ALLGEMEINE ANGABEN:

ANMELDER:

NAME: Epigenomics AG STRASSE: Kastanienallee 24

LAND: Berlin

POSTLEITZAHL: 10435 TELEFON: 030-243450 TELEFAX: 030-24345555

BEZEICHNUNG DER ERFINDUNG: Verfahren zur parallelen Detektion

des Methylierungszustandes von

genomischer DNA

ANZAHL DER SEQUENZEN: 31

COMPUTERLESBARE FASSUNG:

DATENTRÄGER: Diskette

COMPUTER: IBM PC-komtatibel BETRIEBSSYSTEM: PC-DOS/MS-DOS

DATEN DER JETZIGEN ANMELDUNG:

ANMELDENUMMER: nicht bekannt

ANMELDETAG: 6.12.2000

ANGABEN ZU SEQ ID-NO:1:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 12 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:1:

AGTAGTAGTA GT

12

ANGABEN ZU SEQ ID-NO:2:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 12 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:2:

AAAACAAAAA CC

12

ANGABEN ZU SEQ ID-NO:3:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 973 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:3:

AGTAGTAGTA	GTAGCGTTTT	TGAAGTTTTT	TGTGGAAGGT	GAGAAATTTA	TCGATAAGTT	-60
TTTTAGTAGG	AGTGTTTTTG	GGGAGGGAGT	GAGTGGGAGA	TTAGAAATGG	GGTCGGTGGA	120
ATATTTTTGT	AAAATTTTAG	GAATTATTAG	TATTTTATTT	TTTTTTATAA	AGATTGTTTT	180
TATGTTTGAG	TTGTTTTATA	TAGTGTAGAA	ATTGAGAATG	TAAACGTGTA	AACGATCGGT	240
GTGATTTATT	GAAAGGCGAT	GCGCGTTTTT	TTTTTGTAGG	TAGAATTGTT	TTAGGAAGTA	300
TGAAAGTGGA	CGTAGTTCGG	TGTTAGGTGT	TAGCGATTTG	AGTTCGTTTT	CGGGTTTTAT	360
TTATTTTTAG	TTCGGTTTTT	AGATATTTTT	CGAGGCGTTT	TTTTTTGTTC	GTTCGATTTT	420
TGAGCGGAGC	GTTTCGGGGT	GTGAGGAGAA	TCGGTAAATT	TTCGCGGGCG	TTGGGCGTCG	480
TAGAGTCGTC	GCGCGTTTAG	TTTCGTTACG	TTGGTTGTCG	AGCGTATTTC	GGTTGCGTTC	540
GGCGGGGAGG	CGTCGAGGGT	AGTTAAGGGG	AGTAGGTTAC	GTGAGAGGAG	GAGTTTGATT	600
TATTTTTAG	00001110000	TATGCGTATT	TTTTATTTGC	GTTTCGGTCG	GGAGGTTTAC	660
GTGGAATCGT	ACGTGTTTGG	TTTTGTAGTT	AGGGGTTTTT	GGTTCGGGGC	GCGTAGGGGC	720
GGGTTCGTAG	TGGGATTCGC	GGAGAGGGGC	GCGGCGGGC	GGAGCGTTTG	GAGATTTAGT	780
TTGCGGGTTT	CGTAATTATT	ATTCGTGATA	ATTATAGTTT	TTGGAGAGTT	GTTTAGGTTT	840
TTTGCGGGGT	TTTTTACGAA	TTTATTATAT	TTAATATTCG	TGAATTTAGA	AATTAAGATA	900
AAGATTGTAT	TTTTGTTTTG	TAAATTATTA	GTTTCGTAAT	TTAGAATTTA	TTTTGTAAAT	960
GGGTTTTTGT	TTT					973

ANGABEN ZU SEQ ID-NO:4:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 1890 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:4:

AGTAGTAGTA	GTTAAGTTTA	AGAGTGATAT	TTTTTTAGAT	ATAGTATAAT	ATTGTTTTTG	60
TAAAAGGTTA	TTTATATGAA	TATAATGTTT	TTTGGGTTAA	TTAATTCGTT	TTGAGAATAG	120
TTAGGTTAAA	ATTTTTAGGT	TTTTTATTTT	GGGTTATTTA	AGTTAGGATC	GCGACGTGAG	180
TTCGGGGTGA	GTCGAGGGGT	ATTTCGGGTC	GAGGTTATTC	GAATCGAAGT	TATGAGGCGC	240
GGGTCGGTAA	TCGGAAGTGG	TTTAGGGAGA	GTTGTACGAG	ATTCGGGGGT	TGTGATTTGG	300
AAATAAAATA	AAAAAAAAA	AAATTTTAAT	TGTTTTGGGA	TTGATTTTTA	AAAGAGCGTT	360
TTTTTGGTTT	AAGAGGTCGG	CGTTCGCGGA	GATGTCGTTT	TAAAGGGTTG	TTTTTTAAGC	420
GTGTAGGTCG	CGTACGGGTT	TTTTTAGCGG	GCGGGTAAAA	TGGGCGTCGG	TATTCGGGAG	480
GCGTTTGTTT	AGGCGTTCGG	GCGTCGTTTA	TAGAGTACGT	TCGTTTGCGG	TTTTAGAGCG	540
TCGTTTTTTT	GTCGTTTTCG	TCGTTCGGTT	TGACGTTCGG	ATCGCGGTCG	GTTATCGTTT	600
TTCGTTTCGA	CGGTTACGTT	TGTTTTAAAT	CGCGCGGGCG	TTTTTTAGGT	GTTGTTGGGC	660
GGGTTTCGTT	TTCGTGTTTT	AAGGTTCGTT	TTCGCGCGTT	AGTCGCGCGT	TCGTTGTTTT	720
TTTTTCGTTT	TTATAGTTTC	GTTTTTATAG	TTTCGTTCGT	TTTTTAAGTT	TCGTTTTTTA	780
GGAATTCGCG	CGTCGAAGGT	TAGGTTTGGG	CGGAGCGTAT	AGCGTTGGGC	GTTGGGGAGG	840
TTGCGTCGTA	GTATTCGGTT	GGTTAGGATT	AAGTGGGTTC	GAGGCGGACG	TGAGAAGGGT	900
CGGGTTAAGA	TGGCGGTGTA	GGTGGTGTAG	GCGGTGTAGG	CGGTTTATTT	CGAGTTTGAC	960
GTTTTTTTCG	TTTGTTTTAA	TTACGTTTTG	AGTATAGAGA	AGGAGGAAGT	AATGGGGTTG	1020
TGTATAGGGG	AGGTGAGTAG	GTTTGTTAGT	TTGGATGGAA	TTTTGTTGAG	TAGTTTTAGT	1080
GTGTTTTCGG	GGTGGGTGTC	GGTAGTTTTT	AGGGTTGCGG	AGGTTATAGG	TATTTTCGAT	1140
TTAGGTTTTT	GGATATTTTT	TATATAGTTT	TGTCGCGGGG	AGTTTCGTTT	TTTTTGGTCG	1200
TTTGATATTT	GTTTAGTTTT	TTGCGAGTTT	TCGGCGGTTT	GTATAGGTTT	CGGGAGTTTT	1260
GTTTTTTTT	TTGTAGTTTG	GGGTTTTTTT	TTAGATTTGC	GTTTTTCGTT	CGGTTGATTA	1320
AAATTGTAAG	GTAGGTTAGA	AAGATATTGG	AGTATAATGA	GGATGTTCGG	GTATTACGAC	1380
GTAGTAGTTG	ATTATAGTTA	GAGTTTTTTG	TTTCGTTTCG	AGTTTTTTGT	TTAGGGAGTA	1440
GAGATATTAA	TTAAAGTATT	TGAAGGGTAT	CGAAGAGTTT	AATAGAAGGT	GCGGGGTTTG	1500
AAGGAAGTAA	AAGTTTTCGT	TGTATTGTGT	TGAGGAGGGG	TCGAAGAGGA	TGAGGAAATA	1560
TAGTTTAGTT	GTTTATAGTT	TAAAGTAATT	TTTTAGTTTT	TTATATTATG	TGCGTGAATA	1620
TATGATTTAA	TTGTTATATA	ATTTGTATTT	ATATATGTTA	AATAAACGTA	ATGTGATTAA	1680

GTATTGTGTT	TTTTTATAATT	TTTAAGTTAT TTTAAATTAA	TGTTAATTTA	ΔΔΔΨΨΔΨΟΟΟ	ATTGTATTTG GATTTTGGTA TTTTTTTAAT	1000
------------	-------------	--------------------------	------------	------------	--	------

ANGABEN ZU SEQ ID-NO:5:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 2222 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:5:

AGTAGTAGTA	GTTTTGGAGA	GTAAGTGGGT	' ΤΤΤΑΤΌΤΑΔΑ	GTGTTNTTTC		
TTATTTTAN	AGGATTTTAG	AATATTTTCG	AATTCCAAAA	TAGAGTGAGT		60
GGGGGGTGTT	TACGTGGAGG	AGGGTCGCGA	GAAGGAGAGT			120
GGTGTTTCGG	GGGTCGATGT					180
CGGCGGTCGA	GTAGTAGAGG				00000000	240
CGTTTTGTTA	GTAGTCGTTT	CGTCGTTTTT				300
GTCGGTTCGG	GTTTTTGGAA		GGGATAGTCG	ATCGGGGGCG		360
TTTTCGTATT	CGATTCGGAC	GGCGGTAGTA	GGGGGAGGGA	TGGTGTATCG		420
GGTTTTATTA	TTTTGTTCGG	CGGGTCGGCG	GTTCGTTGGT	TCGTTGGTTC		480
TGCGTTTAGG	TTGGTTCGTA	GGAAACGGCG	GCGGCGGTTT	ANTTNTANTT		540
TNNTTGNNAN		TAGGGGAGGG	GTAGGCGGTT	CGCGGGTTTC		600
GGCGATTGGG		AGCGGGTAGG	GTAGGGGGAA	ממייים לא לעדים	CECCACA	660
AGAGTCGGAG	AGCGCGGGAG	GAGTAGCGGC	GAGAGGTAGG	AGAGGTAGAG	AAGAAGAAAG	720
GAGGGAGAGA	GGGGGGGAAG	ACGGTCGGGA	AATTCGGGGT	TGTAGTTTCG	CGTCGCGTCG	780
	GGATTTATTG	TAGCGGTCGC	GTTGATTCGT	AATTTTAAGG		840
	GAGAGGGAGG	GGAAAGCGGA	GTGTTGTAGC	GTCGGGGGGG		900
TCGCGAGCGT	CGTATATTCG	GGAATTTGTN	GTTTCGTTGC	GGGCGAGTGT	CGCGTGTTTT	960
GGCGAGTTTT	GGTTGGGGAA	NTTTGAGCGC	GCGGATTACG	TTCGTTTTTT	AGTCGGTCGT	1020
TTTTTGCGTG		GGAGGTTAGG	GGCGGGGGCG	CGGACGTCGG	TGACGTCGCG	1080
TGGCGGAGTT	TTTTCGGTTA	TGTGGTTGGA	GGCGGGCGGG		AGGTTGGGAG	1140 1200
	AAATGCGAGG	GTTTTTCGGC	GGGAGGAAGC	GCGAGGGGTG	CGCGAGTGTT	1260
	GGATAGGGGT	TTTGGAGTGG	AAGTTTTGCG		AGTAGAGGAG	1320
	GTGTTAGAAT	TATTCGGATG	TCGTATTAAA	AAATAGGAAA	AATTTAAGTT	1380
	TAGTTAAAGG	TATTTGTGTA	TTCGTGTATC	GATTTGGATT	TATTATAGAA	1440
	TATTAGGATT	GTTGTTATTT	CGGTGTAGTA	TTCGTAGGTT	TATTTGTAAT	1500
	AGAGTTAGGA		AAAGATAGAG	AACCCACTTA	AAGTTGGTCG	1560
TAGTTCGAGG	CGTGGGGAGA	ATTTGGGTAA	ACGAGGAGAA	GGGATATTTT	TTATTCGTAG	1620
AAAGATTTTT	TATTTAGTTT	TGTATTTTTA	TAAATCGTTT	AGATTTTTT	TTGGCGGAGT	1680
TTATTAGTTT	TTGTTTAAAA	AAAGAAAAAA	ATTCGAATGT	AGATTGTTCG	TTTATTTTTT	1740
TAGTAGAGTT	ATATTTATTT	TTGTGGTAAT	TATTTTTTTA		ATTATAATAG	1800
GAAATTATAT	TTAGAAAAGT	ATAAGGAGGA		CGAGAGAAGA	AATAAAGTTG	1860
TTAGGAGAGG	TGTGATGAGG	ATAACGAAGA	AAATATTTTG	TAATTATTTT	AATTAGTTAT	1920
TTTTTTATAA	GTTTTGATAA	TCGTTCGTAT	TCGTGTGTGT	TTGAGAGTGT	GTGTGTGTGT	1980
GTGTGTGTGT	GTGAGAGAGA	GAGAGAGGAT	GTTTTTTGAG	TGATCGGAAA	TTTTTTATTG	2040
ATAAAGTTTT	TGAGTTATTT	TATAAAAAGT	TATTGTGTTG	TTTTTTTTT	AAAAACTTTT	
	ATATGAGAAT	TTTATTTTTT	ТТАТСТСТТА	ው መመመመጥ ለ ጥጥ <u>ለ</u>	TATATGATGA	2100
GTATGTATTT	TTTTTTAATA	AACGTTTAGC	GATTTGTTTT		GGTTTTTGTT	2160
TT					0011111011	2220
					•	2222

ANGABEN ZU SEQ ID-NO:6:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 307 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

1.

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:6:

AGTAGTAGTA GTTTCGTT	AC GAATACGATT	AGTTTATATT	GGTTGTTTAG	TATTTCGGTT	60
AGTTTTTGTG GGACGTTG	GC GCGTATATCG	TTTCGTCGGG	GGGTCGGGGA	TTTCGGGGAT	120
TTCGGGGTCG AGGACGAG	GG AGGCGAGTAG	GTCGTTGGTT	TCGACGATTT	TGCGATCGAG	180
GCGTTTGTAG TTGTTCGG	GG CGAGGCGGGC	GATTTTAGGT	TTTCGAGTAT	TTTCGAGATA	240
TTCGCGTTAA GTTTGGTT	TC GGGGGTGGTT	GTCGTCGGGT	TTCGTTTGCG	TTTTTGGTTT	300
TTGTTTT					307

ANGABEN ZU SEQ ID-NO:7:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 523 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:7:

AGTAGTAGTA	GTTGTTGTTG	TTCGAGGTTT	CGGTGTAGTT	GGAAGTTTTG	GAGGTGGGGA	60
GAGGGATGTT	AGGTAAGTGG	TACGGCGAGC	GTAAGGGAAG	GGGTTAGTTA	TTGATTAGCG	120
	TAGGAATCGT					180
TTTCGGGAAA	ATGGTTGTGG	GGTTGGTCGC	GTCGTTAAGT	TTGTTTTCGC	GCGGTGAAGA	240
GCGGGTTGTT	TGGGGGAGTC	GTTTTTTAAT	TTCGCGGCGC	GTTTATTTTT	GCGGAGTTCG	300
TGGTAGGATT	CGAGGGGTTA	CGAGTTGATA	TTTTTTTGGG	TTGTATAAAA	AGTTGAGGCG	360
GGCGTTGGGA	GGAGGTAGCG	GTTGTTGCGG	TGCGGTTTTT	TTTTTTTTT	ATATTTTGTT	420
CGGGTTATTT	TTTTTTTTTT	TTTTTTTCGT	TTTTCGTTTT	TTTTTTTACG	CGGGTTTTTC	480
GGGGTTTTGG	CGGTTTTCGG	TTGAAGGTCG	CGGTTTTTGT	TTT		523

ANGABEN ZU SEQ ID-NO:8:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 653 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:8:

AGTAGTAGTA GTAGCGTCG	GAGTTCGCGT	AGAAACGATT	TGATTTTTCG	CGGCGTTATT	60
TTTTTTTGCG ATTGGCGTT	G CGCGGAGAAA	ATTTAGTTTG	$\cdot TCGATGTTTC$	GTTTATTATT	120
TCGTTTTTAT TTATCGCGC					180
CGGCGAGGTC GTCGGCGGA					240
TAGGTAATTA CGTCGCGGT	CGAGGTTGTA	GATTTTGGTA	GGGGATATAA	TTGGAGAATG	300
AGGGTGGTCG GGTGGGAGT					360
ACGATTCGAG GTTTTTTT	TTTTTTGTTT	TATAGAAAGA	GCGGAAAGTT	TAAGAATCGG	420
GTCGCGTTTG GTTGAGTTT	G ATAATGTTTC	GGTTTTACGC	GTATTGACGT	CGATTTTTGT	480
ATGTTTAGTG TCGTTGCGG	G GTTGGTATTG	CGGTTCGGGT	TTGGCGTTGA	GGAGTTTGGT	540
TTAGTTCGTT TTTGTTTTT	C GCGGAGCGTT	TGGTCGTGGG	TAAGTTTAGG	TTAGGTTGTT	600
TCGGGGACGT AGGGTCGCG	T AGACGTTTTT	TTACGTTTCG	GGGTTTTTGT	TTT	653

ANGABEN ZU SEQ ID-NO:9:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 1461 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:9:

AGTAGTAGTA	GTAGGCGGTG	GTTAGGTCGG	CTCCCCCCCC	mamma		
ATTTAGGTTT	TACGGTCGAG			TATTAGCGGT	TTTCGGAGGT	60
GCGGTCGTTC				GTTTACGGGG		120
	GTTTAGGATG	GAGAGGCGGG		GGTTCGGAGC	GAGTTTTTTA	180
GGGTTTGTCG	ATACGGCGGG			TTCGTACGTG	TTCGAGGGGT	240
TTTCGGGTTT	TCGGTATTAT	GGTTATTATC	GGGGTTTCGA	TTACGACGAG	GTCGATGGTT	300
CGGGTAGCGG	GGGCGGCGAG	GAGGTTATGG	TCGGGGTTTA	CGACGCGTTA	TTTTTCGTAC	360
GATACGCGTT	TTCGGGCGTT	ATCGGGCGTT	CGTTTAGGAT	TTTTCGGGTT	TCGGGTTCGG	420
TTTGCGTTTC	GTTTTTTCGG	TACGGTCGGC	GATTTTTTAA	CGGTTATTAT	TCGGCGTACG	480
GATTGGTTAG	GTTTCGCGGG	TCGGGTTTTA	GGAAGGGTTT	GTACGAATTT	TATAGCGAGA	540
GTGACGATGA	TTGGTGTTAA	GTTCGGGCGA	GGTGGCGTTC	GTTCGGTTTT	TTACGTATTT	600
TACGTATATA	TTTTATTCGA	GGAGTCGCGT	AGAGGTCGCG	GGGGTTTAGT	ATAGAGGGTT	
CGGGAGAGGG	TTAGTCGGGA	GATTTTAGAT	TTTGGAGAGG	TTAGGGTTGG	GTTATAAGGG	660
TGTTTCGTAG	AGATTTTCGG	TTAAAAGAGA	TTTTTTTGGG	TAGTTACGGC	GTTTTTTAAT	720
TAGTTTCGAT	TTTTTTTTTT	ACGATAGGGG	TTTTCGGGTG	GGAGGTAGGG		780
TTATATAGTT	AAGGGATTTG	AATTAATTTA	GTTATTTTTG	GAGAATTTTG	AGTAGATAAA	840
AAAAAAAAA	AAAAAAAAA	AAAAAAAATA	TTTTTAAAAG	AAAAAACGGG	GGGAATATGA	900
TAGTTTTTAT	TGATGAGTTT	TATTATTTTA	ATTGAATTTT		GAGAAAAAA	960
GTTGGTGGTC	GAGTGCGGTA	AAGAAGTTAG	AAGGAATTAG	TTTTTTTTT	GATGAAGATA	1020
ATTATTAGAT	ATATTTATAT	TTATATACGT		AATTTTAGTG	TTTTATATTT	1080
TATATTAAAT	TTTATTATTA	TTGTTTGTAG	TTTTAGATAT	ATATAAGAGT	GTTTGTCGGT	1140
AAATAATTTT	AAAAAGGATA	AAAAAATTAA	AAATTAATTT	AAAAAAATAA	TAATAATAAT	1200
ATTTGGTTTT	GTTTGAAATA	ATAAAAATTAA	TGATTGAGAA	AAGAGGTATT	TTTTTTGAT	1260
TTGTTTTTT	TTTTTTTTT		AAGAAAATT	TATTATTATT	ATCGATTTTT	1320
TATTGTATGA	TATTTAAAAA	TTTTATTTTG	TTTGAAAATC	GTGGGTTTGG	GATTGTGAAT	1380
GATAGGAGTG			ATAAAAAAAA	GTTGAATTAA	AGGGTTTTTG	1440
GATAGGAGIG	GTTTTTGTTT	T				1461
						=

ANGABEN ZU SEQ ID-NO:10:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 2536 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:10:

AGTAGTAGTA	GTAATCGGGT	CGTCGTCGTC	GCGGGGTTAA	GAGATTACCT	TTAGTAAAA	
TTTTTTTAGG	AAAGAGGTTC					60
	TACGTATTAA				TTGATTTTGT	120
CCAAMACAAA	COCCATIAN	AAGGTTCGCG	AAGAAAAACG	CGGGCGAAGT	TTAGTATTTT	180
CGAATAGAAA	000:0:1	TTTAGAAGGG	GGGTTTACGG	GTTTGAGGGT	TTTTGGGTGG	240
GGAAAGTAGT	ATTGGAGGGA	GAAGATAGAA	GGGATGGTAA	CATACACCAA	ATTACCCCCA	
TAAAAAGGAA	GGGATGAGGA	CTTTTTTTTTTTTTTTTTTTTTTTTTTTTTTTTTTTT				300
GTAATGGGTT	TTTTTTCCAAA	DAMCCAMMOO				360
C17271 GGGTT	TTTTTCGAAA	AATGGATTGG	TAGGTTTTTT	CGTATTTTTA	AATAATTTCG	420
TATTATTTGA	AAGCGGGGAG	TTTGAGTTTG	GGGTTGCGTA	GATTAAAGTA	GGGTAAGACG	480
AAGGGAAAGA	GGGAGGGGAG	TTTGGAAGTA		AGAGGTAAAA		
TGGAAATGGA	AACGAGAAAG	GGAGTTCGAA		mm		540
CTTTACAAAT	CCCAMCMMCC	COLOTIONA			TTTGAAAAAG	600
DIMINOAAAI	GGGATGTTGG	GGAGGTAAAG	GGGGATAGTT	TCGAGGAAGG	GTATTTTAGG	660
AATGTAAGGG	AGCGTTTTAG	GTTTTGGGAA		TGGGAGGGCG		720
CGAGGTTCGG	GAGTTGGAAT	AGAGGGGGTT				
				TTTAGGAGGG	GAGAGTAGGG	780
			TAGAGGATGG		TGTTGCGGTT	840
MODDORDAND	TGTGGATTTT	TTTAATGTTA	GGGAGAAGAG	GGAGGTGAAG	CGAGATAAAA	900

6

GGAAAGGGGC	GAATAGGGAG	AAGAGGAAGG	AGTTTGCGAC	GCGATGGGGG	AGGGGAGGGA	960
GGTCGTGGGA	AGCGGTCGGG	GGGCGCGGGG	ATGGGAAGGG	GTCGGGCGGG	CGGCGTGGTT	1020
ATTTTAGGTT	GCGGATTTTT	TTTTTGGGGA	GCGGCGTTGT	CGGCGGGCGG	GTTTCGTAAT	1080
TTTTCGGTTT	TTTCGTTCGT	TTTTTCGTTT	TTTTCGGGCG	GCGGCGGGG	TCGGTACGGT	1140
ACGGTTTATA	GCGGCGGTTT	TTTTGCGTCG	AGTTTCGGAT	GTTGTTTTTG	GGGAGGCGGA	1200
GGTAGCGGTA	GCGGTAGCGG	TTCGGTTCGT	ACGGTTATTA	TCGTTCGCGG	TAGTAGGCGT	1260
TCGCGGGTCG	AGTTTTTTAG	TAGTCGGCGT	CGGCGTCGGC	GGCGGCGGCG	GCGGCGGTTA	1320
TGGTTTTTTG	CGTTTGTTTT	TTTCGTTTTC	GGCGTTTTGC	GGCGGTCGCG	GTTCGATTTT	1380
CGTATTTTGC	GTTTGCGCGC	GGTTTAGTTA	GCGCGGCGCG	TTTTTTTCGC	GCGCGTTCGC	1440
GTTTATTTAT	AATCGCGTTC	GCGGAGTGTT	TTTCGTATCG	TTTTCGGTGC	GTGGGCGGGA	1500
GATATAAGTT	TAGTTAAGTT	TATATAGTTC	GGTTCGGGTG	GTTATGGAGA	GGCGTATTGT	1560
AGAGATATTT	GGACGCGTAT	TGTGATAGGC	GTTATTTTGA	TATACGTGTT	TTTTTATTTT	1620
TAAATATTAC	GGGTCGTAAG	CGTTTATATT	TATATTTATT	TGTAGGGATT	ACGTGGGAGA	1680
ATTTGAAGGG	TTGATTTTGT	TTCGGTGTAT	TCGTAGTAGT	AATGATGCGA	GAATTCGTTT	1740
TAATTTCGTT	ATTGATTGGA	TTAGATTGTA	AATTTTTTGG	CGTTTGGGAT	GGTTTAGTCG	1800
TGTTTAGTAT	TAAGTGTAGG	TATTTAAATT	TTTGTGGAGT	AAGTGATTGG	ATGAATGAAT	1860
GTATTGGAAT	TGTTTATTGA	GTATTTGTAA	TAATTTTGAT	TTTATGGTTT	GGTATAAAGA	1920
ATTTTATTGT	AGTATGAAAT	TAAATGGTGT	TTGTGTGTTT	GTTTTGTTTT	GGTTTAAGGT	1980
TTAAAATAGG	TTAATGTATG	TTTTTTTTT	TTTAACGTAG	AGGAGTTTTA	TTTTGTTTT	2040
GTGTTAGTTT	TTATTATAGA	ATGCGTAATT	TTATTTTAAT	TTAAATGTTT	ATATTTTTA	2100
GGGTAGGAAT	TGTTGTTTAG	AATATATAGT	TTGAAGTATA	TTGTGTGTTT	ATATAACGAT	2160
AGTTTTTTGG	GTTTGGTAAG	ATTTTTTATT	TTTTATTTGT	TTGTTATTTT	GTTTTATTAC	2220
GATTTTŢTGT	AATTTTTATT	TTTATTTTT	TTGTTTTTTA	TTATTATTAA	AATTTTTTA	2280
TTGTTTTTTG	TTTTTTTTTT	CGTTAGTTTT	TGGGGAGTTA	GTTGTTATGA	GTATTTAGTT	2340
TGGTTTTAGA	TGTTGAAAGG	GTTAGTGTAT	ATAGAAGATA	TATATTTAGT	GATGGGTAAG	2400
ATGTTGTAAT	TATATTGGGT	TATGTTGAAA	TTGTGAAGTT	TTAATTTTTT	TATGTGTAAG	2460
AGAAATTAAT	GTATTGTAAT	TTCGATGTTT	GTGTTGAGGA	TTTTTTTGT	AAATTTAAGT	2520
TTTTGGTTTT	TGTTTT					2536

ANGABEN ZU SEQ ID-NO:11:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 504 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:11:

AGTAGTAGTA	GTAGCGCGTT	GAGTTCGGTT	ACGTAGAGCG	TTAGTTCGGT	GCGGTTTTGT	60
AGGTCGGCGC	GCGTGAGTAG	CGGTAGCGCG	AGTATCGAGG	CGTTTAGTAG	GAAGGTGGCG	120
AGGTTGAGAC	GCGTTTTAGA	GTTCGGCGGA	GTTCGCGTCG	CGTAGTTCGT	TATGGCGTCG	180
GGCGGCGGAT	TAGCGGGCGG	CGGCGTCGGT	TGTAGTTCGG	AGAAACGCGT	CGGTTGCGTT	240
TGCGTATTGT	GTCGTCGATG	TCGGTTCGGG	AAGGGTAGTT	GTTCGTAGTT	GCGCGTCGTT	. 300
TGTTAGTTTT	CGCGAGAATT	TCGGTTCGTT	TTGTTGTTGT	TCGGAATTTG	GCGGGAGCGT	360
TTCGTTCGTT	CGTTTTTTTT	CGTTTTTCGG	GGATATTCGG	GTTTTGAGTT	AGATTTTGTG	420
TCGGGCGGGG	GTCGGGAAGT	GGTGGGAGAA	GTCGTCGTTC	GCGTTTGTTT	AAATTTAGTT	480
TTAAATTTAG	GAGGTTTTTG	TTTT				504

ANGABEN ZU SEQ ID-NO:12:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 2036 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:12:

7

AGTAGTAGTA	GTTTTAATTT	GAGTTTAGCG	TATTCGAAGT	' TTCCTTTT 0		
TAGAGATTTT	TAAGTCGGAG					60
TTTCGGTTTT	TAACGGTTCG					120
GTTTTTATT	GTTTTTTAG					180
CGTTGTCGTC	GTTTTTCGGT					240
GTTTTTTTA	GGGGATTATT					300
ATGTTAATTT	AGTTTTCGGA					360
ATTATTAGTA						420
TATAGGCGTA						480
CGTAGAGGAG		***********		111011110	COCTITIOG	540
CGTTTTCGGC			ATTAGTTTAT	TATGATTAGT		600
GGAATACGTA			TAGTCGTCGT	TTCGTCGGTT	TCGTTTAGTT	660
TGTAGGCGGG		CGTCGGGCGG	GGAGCGTATC	GTTTAATTTT	TGGGGCGGTT	720
TGTTTTTTC		ATTTCGTCGT	TCGGTGTGGG	CGTGGGTGTG		780
CGTCGTTTAA		GCGGTTTTTT	TTAAAAAGTT	TTTTTTTAGT	AACGTGATCG	840
TTTTTCGGAT	CGATAATGGT	AATAATTTGT	TTATTTTTAA	GTTTTGGATG	GAGGATAACG	900
ATATATTTT	TTTTTTTGTT	TCGTTTTTTT	TGTTATTTTA	GGTAATATTT	TGTTGTATTT	960
CGTTTATATT	TAAAAAGGGT	AGTAATGTTT	TGTTATTTT	TTGATTTTTA	ATTATTTATT	1020
TTTTTTAGGG	TTGTTTTATT	ATTAGAGGAT	AGTTTTTTT	TTTTTTTTCG	AAGTTTTTAG	1080
GAATCGTATT	CGTTTTTTTA	GGGTAGAAGA	GAGGTTGGGA	GAATATTGTG	ATTATTGGAG	1140
TATGGTGTTT	GTATTTTTA	TTTTGATTTT	AGTTTTTTT	TTTTAGTTTA	TTTTTTTTT	1200
AAGGTGTCGG	TATAGTTTTA	GGATGAGTAG	TTTTGATAAG	TAAAGTTGTA	AGTGTGTGGT	1260
ATATTTTAGG	TTATGTAATT	TTGAGTTTAG	GTTGAGATTT	TTATTATTTT	GAGTAGTTAT	1320
TTATTTTGAT	TTTATTTTTA	AAGAGGTTAA	GGTGTCGTTT	GTAAGCGGTT	TATATTTAAA	1380
TGCGTATGTT	TAGTTAAATT	AATGTGAATA	TAATTTTTGA	GTGGTGTTAT	TTTAGACGGT	1440
ATTATTAATA	ATAATTAGTA	TATTGTTTTT	TATGTGTTTA	TGTTTCGTTA	AGGTGTTAGA	1500
TAAATATTTA	TTATTGTGTA	AGGGAAGGAG	GTTGGGAAAA	TTATGAGTGT	GAGATTTTAA	1560
TTTTTATGTT	ATTTAGAAGA	AGGATTTTTT	GTGGAAGAGT	GGAAATTTTA	AGGGTAATTT	1620
ACGTGATTTT	TAGAGTTATA	TTGTAATGGA	TTTTTTTTT	CGGAGGTAAG	AGATAATAGG	1680
AAAGTTGTAG	TGTTTTTAT	TAGTTGGGTT	GTTTATTTGT	TAGTTAGTAT	TGAAATATTT	1740
AATTGGGTAA	AGTGAAAGTT	TTGTAATTTT	AAGAAAATAT	AGATTAATTA	TATTATTTGA	1800
AAATGTTAAT	GAAAAATTTA	GGATGTGTTT	AATGAAAAAT TAGATAAAAA	GAGTTTTGTG	TTTTGGTGTT	1860
TTATTTTTGT	TTTTGTTTTT	TGATTTAGTT			AAGAGTGTTT	1920
TATTTTGGGT	TGGAAAGGCG			GTAATTGGTA	GTGTTTTGGG	1980
		51000001	GIGIGITIAT	AGGCGGTTTT	TGTTTT	2036

ANGABEN ZU SEQ ID-NO:13:

`;

SEQUENZCHARAKTERISTIKA:

LÄNGE: 452 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:13:

TTTTATTCGG ATTGTTATTT TTTAGGAAAG CGTTTGTTGT GGGGGACGAG	TYDELOGICAL	TATAATGTTA TTGTGTGTTT GTATAAATTA TATGGATGTG TGGAGTTAAG	TATTTTAGAG TTTTTTTTGA TTAGATTATG GTTTAGAATA GTATATTTTA	ATTTTTTT TTAGTTTTGT ATATTTATTT GTTGGTAGTA	ATTTGTAGAT	60 120 180 240 300 360 420 452
--	-------------	--	--	--	------------	---

ANGABEN ZU SEQ ID-NO:14:

SEQUENZCHARAKTERISTIKA: LÄNGE: 513 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:14:

AGTAGTAGTA	GTAGCGGAGA	CGGAGGCGGC	GGCGGAGGCG	GCGGCGGCGA	TTTTAGCGCG	60
GGGCGAGCGG	CGGGGTTTAT	GGTCGGATTC	GGCGAGTTGG	TTTAATAGTG	GGGTTAGGGG	120
TTTCGGGCGC	GGGGGGGATC	GGAGGGAGCG	AGGTCGTTGT	CGGACGGGGC	GGGGCGTCGG	180
GAGGGGCGGG	GTCGCGGTCG	GACGGGGCGG	GGTATTAGGA	GGAACGGAGT	GGGCGTTTGG	240
	GTTTAGATTG					300
	AGGGAGTTGG					360
TAGAGAGAGG	AGGTGTTTCG	GTAGCGGACG	CGTTAGCGGG	GTAGATAGGA	AAATAGTTGG	420
AAAGGGCGAT	TTGGGGGAGT	AGAGATACGA	TTAGAGTTTG	AGAAGGGTAG	GAGTAAGGGA	480
TGTTTAAGGG	GTTTGGTGGT	AGGTTTTTGT	TTT			513

ANGABEN ZU SEQ ID-NO:15:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 980 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:15:

AGTAGTAGTA	GTATTTTCGG	TTATAAGGAT	TTTTCGAGTT	TCGTTCGTCG	GTCGCGGATT	60
CGGTTTTTTT	TTTTTCGGTC	GTTAGGGGGC	GGGTTCGGAT	TATAGGATTG	GAGTTGGGCG	120
GAGATTTACG	TTCGGAGCGG	TTGTGAATTG	GTAGGCGGTG	GGCGCGGTTT	TTGTGTCGTG	180
TTTCGGGTAT	TTAGTTTTTT	AACGGGGTTT	CGGAGTCGAA	GATAGTTTTA	GGGTTTAGGG	240
AGCGCGGGCG	GTTTTTGGGC	GGCGTTAGAT	TGCGGTGAGT	TGGTCGGCGT	GGGTTATTAA	300
TTTAATGTAG	TTTAGGGCGG	CGGTACGAGA	TAGAATAACG	GCGAATAGGA	GTAGGGAAAG	360
CGTTTTCGAT	AGGTTAGGTT	TAGGGATTTG	CGGGGAGAGG	GCGAGGTTAA	TATTCGGTAT	420
GGGTTTTTGA	TTGGTTTTTG	GGATTCGTTT	CGTTTACGTT	TATAGGTGGG	TTCGTATTTT	480
TTTTTGCGTT	TCGTTTTCGT	TTTAATAGTT	TATAGTTGTT	GTTAGTTTAT	TCGTACGTTT	540
CGAATTTCGT	TCGAATTCGT	TATTGGTTGT	TTTTTAGCGG	TTTGTGTTGA	TTGGTTGTTC	600
GAAGATTCGT	TTTTTTGTCG	TGGGTTTAGT	TTCGTAAATG	CGTAGTTAAG	CGGGTGGTAA	660
GGGGCGGGTG	GAGCGCGGGG	CGCGACGGCG	GAGGGGGGCG	TGGGTAGTCG	GACGTATTTT	720
GGTAGGGAGT	AGTAGGTGGC	GGCGGTGTAT	GGGGTTTGGT	TTTATTAGCG	GGTATTGGTT	780
TATAGTTACG	GTCGGGGGGT	TATTTAGTTG	GAGAGAGAAG	GGATAGGTGA	TTCGATCGGA	840
GTTTAGTTTA	GTTTTTAGCG	GTGGGGCGAG	AGATAGCGAG	GGGAATCGAG	GTTGGGGAGG	900
TTATTTAGGG	AGATTTCGGA	GGGAATTTGG	TGAGGTTTGA	ACGGAGGGAG	ATTTGGGGTT	960
GAATAAAGGG	TTTTTGTTTT					980

ANGABEN ZU SEQ ID-NO:16:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 223 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:16:

AGTAGTAGTA	GTAATATTAT	TTTATTAAAA	AAATATTAGC	GTAGTTTTTA	ATAGAGTTTT	60
ATTTTTTAAA	GTGAAGTTAA	AAATAGGTTT	TATGTTTAAA	GTTTTTTTC	GTAGTAGGCG	120
ATACGCGTAG	ATGGAGAAAA	TATTTTTATT	GTTGGGAAAG	GGAGGCGTGT	TAACGGGGAC	180

GAAGGATATT TTATTATTTG GTAAAGTTAT TGGTTTTTGT TTT

223

ANGABEN ZU SEQ ID-NO:17:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 1145 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:17:

AGTAGTAGTA GTTTTGGGT TTGTATTTAG GTTACGTTT TTTAGTTCGT TTTTTGGTTT TTTCGTTTAT TTTTTTCGG AAGTTTTTTT TTTGGCGAT TTGGGGCGGT TTGTAGTTT AGCGATTCGT TTTCGTCGT	T TTTAGATTCG A GGTTTTTTT T TTTTTTTAGT AGGTTTTTTT I ATCGTCGAGG	TTTTTTTTA TGTTTTTTC TTTGTTTTTC ATTATTTAGG AAGAGGAAGG	TTAGATTACG GTTTTGAATT GGATTTTGGT GTTCGTTTTT CGTTCGTGGT	TTGGTGGGG TTTATCGTTT TTGTTTCGAG CGAGTATTTT GTTTGTTCGT TTGGTTTCGT TACGTCGATA	60 120 180 240 300 360
GCGTTTGGAT TGAGATTTG GGGGAGGGG TCGGGGATA GATAAGGGAT AGTTGTAAT' AGTTGTGTGT TTCGAGTTT' TTTATTTTGG TAGGGGATG' GTGGTTTTTT TGTTGGCGG GGTTACGAGG TTGAGTAGAA GAGGTTGTAG TCGGGGGTTA TTTAGTTGAG GAGTTCGTT'	A GTTTATAAGT GAGTTCGGGG GGGGGTTTGA TGGAGTAGAT TTTAGTAGTT TGTTTTTATT TAAGGGTAGG	AGGATTTGCG CGAGGGGCGG TGGAAGGGGT AATGTTTTTT GTCGTGGTTG GGTGGTCGTG TTGGAGGTTT ATGGGTTTAG TTTTTTTGG	GTTATTGTCG GGTTCGTGGC GGGCGTTTCG GATATTTTGTT GAGAGTATTA CGTTTTATTT GTTTTTTTTA	CGGGAGTTAG TTATTAGGAC GGTTTCGGTC TTATGGGTTT CGGGCGGAGT ATAGGTTATT TGAGGACGTT TTATGTTATT TTTCGAGGTT	600 660 720 780 840 900 960 1020
GTTTT		***************************************	TATTTTTGTT	TGAGGTTTTT	1140 1145

ANGABEN ZU SEQ ID-NO:18:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 633 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:18:

AGTAGTAGTA G CGTGCGGACG G GAGTTCGGAG T GAGAGCGGTG G CGCGGGAGTC G TGTTTCGATA G TTTTTATTTG CC TCGCGTTCGT T TAGTTTAGGC G GTAGTCGAGG T AGTTGGTCGG G	TTGGAGGG TTTTTTTT TAGTTTTTT GTGCGCGTC GCGTTCGTT TTCGGATAG CGGAGGGAG TGGTCGGA	TGGGGAGGTT CGGTTTTCGT TCGGGGGGCG GCGCGAAGGA TTATAAAGCG TTTTTGTTCG CGAGTTCGTT GAGGGTGAGT	AGTTCGGGT TCGCGTTTAG CGTTAGTCGA GATTCGGTT ATGTAGTCGG TTGTTCGTT TCGCGCGT TCGAGGTAGG	AGTTCGCGTA GGTCGGATCG TCGGGGCGTT CGGCGGCGGT TTTGATTTAT CGTTTTTAT GTAGTTTTAT	TTCGAGTTTG GAGGGAGAGG GGGCGGGCGT ATTTAGTTTT TAGCGTTTTT TTTTTAATTT TTTTTAGCGG	60 120 180 240 300 360 420 480 540 600 633
---	---	--	---	---	--	--

ANGABEN ZU SEQ ID-NO:19:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 12 Basen ART: Nukleinsäure STRANGFORM: Einzelstrang TOPOLOGIE: linear ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA SEQUENZBESCHREIBUNG: SEQ ID-NO:19: AGTAGTAGTA GT 12 ANGABEN ZU SEQ ID-NO:20: SEQUENZCHARAKTERISTIKA: LÄNGE: 12 Basen ART: Nukleinsäure STRANGFORM: Einzelstrang TOPOLOGIE: linear ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA SEQUENZBESCHREIBUNG: SEQ ID-NO:20: ACAAAAACTA AA 12 ANGABEN ZU SEQ ID-NO:21: SEQUENZCHARAKTERISTIKA: LÄNGE: 74 Basen ART: Nukleinsäure STRANGFORM: Einzelstrang TOPOLOGIE: linear ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA SEQUENZBESCHREIBUNG: SEQ ID-NO:21: AGTAGTAGTA GTTTCGGTAG TTTAGTTTAT GGCGGCGGTG GCGGCGGTAG TAGGTTTGAG 60 TTTTAGTTTT TGTT 74

ANGABEN ZU SEQ ID-NO:22:

SEOUENZCHARAKTERISTIKA:

LÄNGE: 103 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:22:

AGTAGTAGTA GTAGCGGTAG CGGTAATAGG GCGGTTGAGA ATTCGGCGGC GGCGTTTTTT 60 TTCGTTTTTT TTTTTTCGT TTCGTCGATT TTTAGTTTTT GTT 103

ANGABEN ZU SEQ ID-NO:23:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 559 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:23:

AAAGTTAAGT GTTTTAAATA AAGGGTTTAT TTTTTTTT	TTATTCGTAT AATTATTTGA TTTACGAGAT ATCGAGGATT GAGTTTTAG	GGTTTTTAAT TTAGTTAAAA TGGTGTTAGA TATTAAGTAT ATAGTATGTT AAATTAAAGG	TTATTTTTGT GTTGAAAATA AGGTAATAAA TGTTTCGTGA TTTGATTTAA AAGGATTGGA	TTTGGGTTTA AGTGGTCGGA TTTTATTTTT GATTATTGAA AACGTTTTAA AATGTTAGGG	60 120 180 240 300 360 420 480 540
	AAAGTTAAGT GTTTTAAATA AAGGGTTTAT TTTTTTTT	AAAGTTAAGT TTATTCGTAT GTTTAAATA AATTATTTGA AAGGGTTTAT TTTACGAGAT TTTTTTTTT ATCGAGATT AGATATTTG GAGTTTTTAGTTTTT TAATAATATT GAATTATTA	AAAGTTAAGT TTATTCGTAT TTAGTTAAAA GTTTTAAATA AATTATTTGA TGGTGTTAGA AAGGGTTTAT TTTACGAGAT TATTAAGTAT TTTTTTTTTT ATCGAGGATT ATAGTATGTT AGATATTTGG GAGTTTTTAG AAATTAAAGG GTTAAATAAT TTTGATTTTT ATGGTTGTGA TAATAATATT GAATTATTA AACCCATTAC	AAAGTTAAGT TTATTCGTAT TTAGTTAAAA GTTGAAAATA GTTTTAAATA AATTATTTGA TGGTGTTAGA AGGTAATAAA AAGGGTTAAT TTACGAGAT TATTAAGTAT TGTTTCGTGA TTTTTTTTTTT ATCGAGGATT ATAGTATGTT TTTGATTTAA AGATATTTGG GAGTTTTTAG AAATTAAAGG AAGGATTGGA GTTAAATAAT TTTGATTTTA AACGCATTAC TATGATGTTGT TAATAATATT	GTAAGAAGGA AAAAAATAAA TTTTTTAAGT TTTTATTTCG AAAGTTAAGT TTATTCGTAT TTAGTGTAAATAA AATTATTTGA TTAGTGTAAAAAAAA

ANGABEN ZU SEQ ID-NO:24:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 1695 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:24:

AGTAGTAGTA AGGATTTTAG AGATTTTCG AATATTTTCG AATTCGAAAA TAGAGTGGGT GGGGGGTGT TACGTGGAG GGGCGGGT GGGTCGATG GGGTCGATG GGGTCGATG GGGTCGATG GGGTCGATG GGGTCGATG GGGTCGATG GGGTCGATG GGGTCGATG GGGCGGGT GGGTCGATG GGGTCGATG GGGCGGGT GGGCGGGGG GGGCGGGG GGGTTTCGG GGGCGGGT GGGTTTCGG GGGTCGATG GGGCGGGT GGGGCGGGG GGGGCGGG GGGTTTCGT GGTAGTAGAGG GGCGTTTCGT GTAGTCGTT CGTCGTTTTT TTCGGTTCGT TTTTGTATA TTTTGTTA GTAGTCGTT CGTCGTTTTT TTCGGTTCGT TCGTAATCGT GTTTTTAAGG GGCGGTAGT TTTTTAAGG GGGGGGGG TTTTTGGAA TTTTTTACGG GGGGGGGGG TTCGGGGGGG TTCGGGGT TCGGGGTTC AGGGGTTGG GGGGGGGG GGGGGGGG GGGGGGGG TTTTTGGTT TTTTGTTA TTTTGTTCG GGGAAACGGC GGGGGGGG GGGGGGGG GGGGGGGG

ANGABEN ZU SEQ ID-NO:25:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 722 Basen

٠٠,

ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:25:

AGTAGTAGTA	GTTTCGTTAC	GAATACGATT	AGTTTATATT	GGTTGTTTAG	TATTTCGGTT	60
AGTTTTTGTG	GGACGTTGGC	GCGTATATCG	TTTCGTCGGG	GGGTCGGGGA	TTTCGGGGAT	120
TTCGGGGTCG	AGGACGAGGG	AGGCGAGTAG	GTCGTTGGTT	TCGACGATTT	TGCGATCGAG	180
GCGTTTGTAG	TTGTTCGGGG	CGAGGCGGGC	GATTTTAGGT	TTTCGAGTAT	TTTCGAGATA	240
TTCGCGTTAA	GTTTGGTTTC	GGGGGTGGTT	GTCGTCGGGT	TTCGTTTGCG	TTTTTGGTTT	300
TTGTTTTTGT	TTCGACGTTT	TTGTTAATTA	GTATTTTTT	TTTTAATTTT	TTTTCGATTT	360
TTATTTTACG	TTTTTGTTAA	TTTGTTTTT	TTTTTGTTAT	TTTTCGACGT	TCGTTTTTT	420
TTTTTTTGTT	TTTTCGTTTT	TCGTTAAGGT	ATTATTTTGT	TTATTTATTT	AGCGTTTTAT	480
TTTGTTGATT	TGGGATTTTA	CGAGTTTTTT	TGTTCGTTGT	TTTTTATTGG	GTAACGTTCG	540
GGGTAGTTAT	TTGTTTTTTT	CGGGATTTAC	GCGGATAGTT	TTTCGTTTTT	GATTTTTGGG	600
ATATTGGTTA	GTTTTGTCGC	GATATTAGCG	CGTNTTTTCG	TATTTTCGTT	CCCCCTTCC	660
GTTTTCGTTC	GTCGTTTGTA	GTTTTTATTT	TTGAGTCGAC	GTTCGTTTAT	TTAGTTTTTG	720
TT						722

ANGABEN ZU SEQ ID-NO:26:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 517 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:26:

AGTAGTAGTA	GTTCGAATTC	GCGCGCGTAG	CGGCGTATGG	TTAGGTTTAG	CGAACGTAGT	60
TTTAGCGAGT	GGCGCGTTAG	GCGTATTACG	TAGAGTACGC	GTAGCGTACG	TAGTAGTCGT	120
AGTATTAGTT	TCGCGCGTTT	TAGGAGTTTG	GTTTCGTTCG	GGTTTGTCGT	TAGTTTTAGT	180
AGTAGCGATA	CGTAGAACGG	TAGGAGCGTT	AGGATGTTAA	TGATGTTGAG	TGGCGCGCGT	240
AGGAAGGCGT	ATTTGTTTTC	GGTTTGTAGG	GAGCGTAGTA	GGAATTCGAA	GGAGAATTAG	300
GTTACGTATA	CGGTTTTTAG	TACGAATAGG	TTGCGGTATT	TGGGGGAGTA	TTCGTTTTGC	360
GGGGAGAGGG	GATACGGGGT	TGGGGGCGTA	GGTTTTTTGG	AGGGTCGGGG	GCGTTTTGTT	420
TTTTTTTTT	TAGGATTAGA	GGCGTTTTTT	AGGTTATTTT	TTTCGTTTTA	ATTTACGGAA	480
GCGGGTGTAG	GGGATATTGA	TAGGTTTAGT	TTTTGTT			517

ANGABEN ZU SEQ ID-NO:27:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 1078 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:27:

AGTAGTAGTA	GTATTAGTAA	TAGTAGTACG	AAAAGTAAAA	TTGTAATTTA	AACGGTTTTT	60
AGGGTTTAAG	TAGGTTCGAC	GAAGATTCGT	TTATTCGGTC	GTTAGAAAAT	TGGGAGTTTC	120
GTTCGTTTTT	TCGGTATTGA	AACGCGATCG	GTTTTGTTTG	GTATCGTATT	TTTTTTTGA	180
TTTTATTTAT	ATTACGACGA	CGGACGTTCG	AGAACGTTGT	ATCGCGTTTC	GTAGGAAGTG	240
TTTTTTTGGG	CGGAAGTTTT	TGAGCGTGAT	ATAGCGGAAG	TGTTTTTTT	TTCGGTTTTT	300
TTGGTTTCGG	TCGTAGAAGC	GAGATGGTGA	GTTGTGATTG	TGGTGTTTGT	GAATCGCGTT	360

GAGGGAAGGA TTTTTTGGTC GGTTTTAGGT TTTTTTCGTA GAGAATTCGA	TGGTGGGTTG GTGTTTGGG TCGGTTTAAT GTTTGGGAAT GGAGTTTGTA AACGTGAAAT GTTTCGATTT GTAAATTTAG AACGTTATCG TAAGGTTTAT	GAAAGAGGTA GATTTATTTC TTTTGGAGAT GTTTGGTTTT AAGATAAGGT GCGGGTAGTG TTACGATTGT AAGTTGTTAG TTTGGAAAGC TATTTTTAGA	TGCGGTGGTT GTCGTAATTG TTTTTACGGT GTGTAATAAT GTATTTTAGA GTTTTTGATT TTTTAAATTT GTTTTAGAAT GTCGTAATAA AGTCGATTTG	TTTAAGAGTT TGGTGTTAGA TTTAGTTTTG GAAATAATTT ATATTGTAAT TGGTATTCGT TATTAGTAAT TATTTATTTT GACGTATACG TGGTAAATGT	GTTGGGAGTC ATTGGTGATG TTTTGCGGAG GGAAAGAGGT TGGTTTTTCG TTTAATGTGT	420 480 540 600 660 720 780 840 900 960 1020 1078
--	--	---	--	---	--	--

ANGABEN ZU SEQ ID-NO:28:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 2949 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:28:

AGTAGTAGTA	GTCGTAGGAG	TAGCGTTTTC		_		
TCGTGGTTAT						60
GTTTTAGCGG						120
CGCGGGTTTT						180
TTTCGTTTAT						240
TTTTTTTTAG						300
TTTTTTTTT						360
AAATTTTTC						420
GTTGGTTTTT	GTTTTTTTT					480
ATTTTTTGCG	ATGGTGTATT					540
AAATAAGAGT	TTTTTTTTAT					600
TTTGGGTAGA						660
TGTCGAATCG	TTTTGTTATT	TTGTTGTTGA			AAAAAATGA	720
AGTAGTTGTT	TGGAGAAGGA	GGAGGAAGAA		TGGTGTTTTA		780
GTGTATATAG	GGGATCGATT	TTTGATATAT				840
GTAGAGTGTA	TCGACGGCGG	GCGTTGGCGT	AATAATTTTA	GTGGGTACGT		900
GTTCGTTTTG	CGTTTTCGTT	CGCGTTTTTT	TGGTCGTGTT	GGAGTAGAGT		960
TTTTTTTTT	TTTTTTTCG	GGCGTTCGTT	TTTTTTTTT	TATTTTTTT	TTTTTTTTTT	1020
TTTTTTTTT	TAGAGCGGGG	ATTGTCGAAT	TTCGTTTCGA	TTTGATAGTT		1080
TATTATATTT	TTTTAAATAT	AAGGAAGTCG	GTTTATTTT	CGTCGCGAGC	GCGTATTTAT	1140
TTGGGTGATT	GGTAGGTTCG	GAATGATTGG	AGTATTAGGG	TTTTCGTTGA	TTGGTTATCG	1200
TTCGATTGGT	TGTTTTTTAA	TTTAGGTAGA	TTTAGGACGC	GAGGTTTTTT	TTTCGGTCGT	1260
TTAGTTTTTT	TTTTTTTTAT	TATTTTTTT		AGTTGGAAAT	TTGTCGTTTT	1320
TATATTTTAA	TTTTTAGTGT	TCGGTTTAGA	TTTTCGTTTT	TTTTTCGTCG	TTTTTTTCGT	1380
CGTAATAGGT	TTGGGCGGGG	GGAAGAAAGG	CGTTGGCGTT	TTTTCGGCGG	TTTTGGCGTT	1440
GGGAAGAGAA	TTAGAAGGAA	AACGAAGGGG	GGAGATAAAA	GGGAGGGAGG	GACGAGAGGG	1500
TATTTAGTAC	GCGTCGGGTT	GTTTATTTTT	GAAATATGAA	AAATAGTAAT	TTGTTTATTT	1560
CGCGCGGTAC	GGATGTATTA	TTTAAGTTAA	TTATTTTCGT	TTCGTTAGAG	ATTTGTAAAG	1620
TTAAAGTTTT	TTTTTTTTT	TATTAGTTAA	TATTTATAGA	TAGATGTGTT	TTTAGTGGTT	1680
CGGGGGTTCG	TATCGTTAAG	AGTTTTGGTC	TTTTTTTTT	TGATCGGCGG	GGGTGGGAAG	1740
TAATTTTTCG	TAGTCGTTGC	GCGTCGGCGG	GTGGTTACGT	TTTTTGGAAA	TTCGTTATCG	1800
	AAATTTGTAG	TTTAGGANNT	TAGTTTTTTT	TGTTTAAGTT	TTCGGATGTT	1860
	GTTTTTTGGT			CGCGTGCGAG	ACGGATCGTT	1920
TTTTTTTTT		TTTTTTTTTT		TTTTTCGTTT	TTTTTTTTTT	1980
				CGTGTTTTTG	TGAGTTTGGA	2040
	CGTAAGTGTA			AATTAGTTCG	ATTTTTTTT	2100
				AAATTTTTGT	GGTATTAGGA	2160
DOG! COMM	AGAACGGGGA	TCGGTTATTC	GCGTTTTTTT		GTTTTTTCGT	2220
						~ ~ ~ 0

WO 01/42493 PCT/DE00/04381 14

GTGTGTGTGT	GTGTGTGTGT	GTGTGTGTGT	GTGTGATTAG	CGGTGGGGG	GTTTGTTCGT	2280
TTTTTATTTT	TAGGTATGGT	GGTGTTTTTT	TTTTTTTTTT	TTTTGTTTTA	GATGGATTTG	2340
CGTGGTGGAT	GGGGTTGGCG	GCGATAAATG	TTTTTTTAGT	TTTAATTTAG	TTGAAAGAGT	2400
TAAGGGGGAT	GGGAGGGGA	GTGTATTCGG	TAGGCGAGAG	AAGCGGGGGT	GGGGTGGGGT	2460
GGGGTGGGGG	GACGCGGTTA	AGCGGAAACG	TTGTATAGAG	GAATTTTAGC	GAATTAAGAA	2520
AAAAGAGAAA	GTGGTAACGA	AAATAAGGGT	AAATTGAGTT	TTTTTCGGGG	ATTTTTAATG	2580
ATTAATTTA	ATTCGGATAT	TTAATAAATA	TATGGTTTTT	AATGAGCGTG	CGTGTGCGTG	2640
TATTTCGTAT	TTTTAGTTGC	GGGTGCGTTC	GTTTGCGTTC	GTCGTTTTTA	GTTAGAGTTT	2700
GTATTTGGTA	GTTTCGAGTT	CGAGCGGTAG	TTTAGGACGT	AGTCGAGGAG	CGTCGTCGGT	2760
GCGTTTCGAT	TAAAATGTGA	ACGGGTTTGT	TTTTTTTTT	CGTTGTATCG	TGTTTTTGTC	2820
GAGCGTAGTT	AAGTGAATTT	AGTGAAAGTA	GGAGTTTTTT	TGTTTAGTCG	TAGTTAGGTA	2880
GTTTTCGCGT	GATTTTAAGA	TTAATATTAG	ACGCGTAGAA	TTTATGTAGG	TTTTTGTTTA	2940
GTTTTTGTT						2949

ANGABEN ZU SEQ ID-NO:29:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 117 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:29:

AGTAGTAGTA	GTTTATTTTG	GGTTGATATA	AAATTGAAAA	ATTTATTTGT	TTTTTTATTT	60
TTTTGGGTTG	GATTCGGTGT	ATCGGTTGAT	ATATTTTTTT	GGTTATTAGT	TTTTGTT	117

ANGABEN ZU SEQ ID-NO:30:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 639 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

SEQUENZBESCHREIBUNG: SEQ ID-NO:30:

AGTAGTAGTA	GTATTATGGT	TATTTCGACG	GTCGCGTTCG	TTATTTTTTT	GCGGCGGTTT	60
AGTCGCGACG	TTGTTAGGGT	TAGTAAATTT	TTTTTATTTT	TGGGCGTAAT	GGTTGTCGGG	120
GTCGGGGTTT	TTCGCGGGTT	AGGAGGCGGT	GATTCGTTTT	GGGTTTGGGT	TTGTATTTTT	180
TCGACGGTTG	TTTTTCGTTT	TTTTTATTTT	GTTTTTGCGG	GTTTTAGTCG	CGGCGGTGTC	240
GTTTTTTAAG	TCGTTCGTTA	AGGGGAGGTT	TTTCGTGGGT	TACGTTAGGG	GTAGTTTTCG	300
ACGGTTTAGA	GTTAGTGGTT	TTTTAGTATT	TTTTCGTTTA	GTTTTAACGA	TTTTGGGTAT	360
TTGAGATTCG	CGGTTTTTCG	GACGGTTGGT	TTTTTAGGGA	TTTGAGATGT	TTGTTTTTTA	420
GATTGTTGTT	TTTTTAGGGA	TGGCGCGGTG	TTTGGGTTTT	AGATTGTTTA	GATAGATTAT	480
TTTTTGATGG	AGAGGGGATT	GTTTTTCGCG	TTTCGGACGT	TTCGGGTTTT	GAGTTGCGGG	540
TGTTGTTTAT	CGGGCGCGAT	TTTTTAGTAG	GTTTTGCGTT	TTGTTTTTTG	GTAAGTATCG	600
ATTTATTTTG	TTATTTTTGT	CGCGGTTTTA	GTTTTTGTT			639

ANGABEN ZU SEO ID-NO:31:

SEQUENZCHARAKTERISTIKA:

LÄNGE: 304 Basen ART: Nukleinsäure

STRANGFORM: Einzelstrang

TOPOLOGIE: linear

ART DES MOLEKÜLS: chemisch vorbehandelte Genom-DNA

WO 01/42493

PCT/DE00/04381

15

SEQUENZBESCHREIBUNG: SEQ ID-NO:31:

GAGTTCGGAG GAGAGCGGTG	TTTGGAGGGG GTTTTTTTT	TGGGGAGGTT CGGTTTTCGT	AGTTCGGGGT TCGCGTTTAG	AGTTCGCGTA GGTCGGATCG	GGAGGGTTTT TTCGAGTTTG GAGGGAGAGG GGGCGGCGT ATTTAGTTTT	120 180 240 300
						304